



Controle Estatístico de Qualidade

Volume Único

Henrique Martins Rocha



GOVERNO DO ESTADO
RIO DE JANEIRO
Secretaria de Ciência, Tecnologia e Inovação

**UNIVERSIDADE
ABERTA DO BRASIL**

MINISTÉRIO DA
EDUCAÇÃO



PÁTRIA AMADA
BRASIL
GOVERNO FEDERAL

Apoio:



Fundação Cecierj / Consórcio Cederj

www.cecierj.edu.br

Presidente

Gilson Rodrigues

Vice-presidente

Marilvia Dansa de Alencar

Coordenação do Curso de Engenharia de Produção

CEFET – Diego Carvalho

UFF – Cecília Toledo Hernández

Material Didático

Elaboração de Conteúdo

Henrique Martins Rocha

Diretoria de Material Didático

Bruno José Peixoto

Coordenação de Design Instrucional

Flávia Busnardo da Cunha

Design Instrucional

Vittorio Lo Bianco

Biblioteca

Simone da Cruz Correa de Souza

Vera Vani Alves de Pinho

Diretoria de Material Impresso

Ulisses Schnaider

Revisão Linguística e Tipográfica

Beatriz Fontes

Ilustração

Vinicius Mitchell

Capa

Vinicius Mitchell

Programação Visual

Alexandre d'Oliveira

Produção Gráfica

Fábio Rapello Alencar

Copyright © 2019 Fundação Cecierj / Consórcio Cederj

Nenhuma parte deste material poderá ser reproduzida, transmitida e/ou gravada, por qualquer meio eletrônico, mecânico, por fotocópia e outros, sem a prévia autorização, por escrito, da Fundação.

R672c

Rocha, Henrique Martins.

Controle Estatístico de Qualidade. Volume único / Henrique Martins Rocha. – Rio de Janeiro : Fundação Cecierj, 2019.

406p.; 19 x 26,5 cm.

ISBN: 978-85-458-0223-5

1. Estatística. 2. Métodos estatísticos. 3. Controle de qualidade.
I. Título.

CDD: 519.15

Governo do Estado do Rio de Janeiro

Governador

Wilson Witzel

Secretário de Estado de Ciência, Tecnologia e Inovação

Leonardo Rodrigues

Instituições Consorciadas

CEFET/RJ - Centro Federal de Educação Tecnológica Celso Suckow da Fonseca

Diretor-geral: Carlos Henrique Figueiredo Alves

FAETEC - Fundação de Apoio à Escola Técnica

Presidente: Alexandre Sérgio Alves Vieira

IFF - Instituto Federal de Educação, Ciência e Tecnologia Fluminense

Reitor: Jefferson Manhães de Azevedo

UENF - Universidade Estadual do Norte Fluminense Darcy Ribeiro

Reitor: Luis César Passoni

UERJ - Universidade do Estado do Rio de Janeiro

Reitor: Ruy Garcia Marques

UFF - Universidade Federal Fluminense

Reitor: Antonio Claudio Lucas da Nóbrega

UFRJ - Universidade Federal do Rio de Janeiro

Reitora: Denise Pires de Carvalho

UFRRJ - Universidade Federal Rural do Rio de Janeiro

Reitor: Ricardo Luiz Louro Berbara

UNIRIO - Universidade Federal do Estado do Rio de Janeiro

Reitor: Luiz Pedro San Gil Jutuca

Sumário

Aula 1 • Introdução ao controle da qualidade.....	7
<i>Henrique Martins Rocha</i>	
Aula 2 • Métodos estatísticos para o controle e melhoria da qualidade.....	51
<i>Henrique Martins Rocha</i>	
Aula 3 • Ferramentas para o controle da qualidade: estratificação, folha de verificação e diagrama de dispersão.....	77
<i>Henrique Martins Rocha</i>	
Aula 4 • Ferramentas para o controle da qualidade: gráfico de pareto	115
<i>Henrique Martins Rocha</i>	
Aula 5 • Ferramentas para o controle da qualidade: diagrama de causa e efeito e histograma	147
<i>Henrique Martins Rocha</i>	
Aula 6 • Ferramentas para o controle da qualidade: gráfico de controle	177
<i>Henrique Martins Rocha</i>	
Aula 7 • Ferramentas para o controle da qualidade: gráfico de controle (continuação).....	217
<i>Henrique Martins Rocha</i>	
Aula 8 • Ferramentas para o controle da qualidade: gráfico de controle (continuação).....	257
<i>Henrique Martins Rocha</i>	
Aula 9 • Ferramentas para o controle da qualidade: gráfico de controle (continuação).....	301
<i>Henrique Martins Rocha</i>	
Aula 10 • Análise da estabilidade e capacidade do processo.....	327
<i>Henrique Martins Rocha</i>	
Aula 11 • Inspeção da qualidade	353
<i>Henrique Martins Rocha</i>	
Aula 12 • Inspeção da qualidade (continuação).....	381
<i>Henrique Martins Rocha</i>	

Aula 1

Introdução ao controle da qualidade

Meta

Apresentar a evolução histórica do processo da qualidade até a fase da normalização que incentiva empresas de vários setores a alcançarem o Prêmio Nacional da Qualidade (PNQ).

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. narrar como se deu a evolução histórica do processo da qualidade;
2. apontar quais as normas que abrangem a área da qualidade;
3. explicar o prêmio de excelência dado às empresas que exercem um bom desempenho no setor da qualidade de produtos e serviços.

Pré-requisitos

Funções estatísticas e distribuição normal, conteúdos abordados nas disciplinas Estatística I e II, que são pré-requisitos para a presente disciplina.

Introdução

Ao ler este material, você está vivenciando o final de um longo processo, no qual diversos profissionais e recursos foram utilizados para gerar um material adequado para seu estudo: professores desenvolveram a estrutura curricular do seu curso, as ementas das disciplinas, bem como seus objetivos e bibliografia. Outros professores pesquisaram e desenvolveram o conteúdo que você lê agora, o qual passou por revisores, diagramadores, etc. até estar pronto para seu uso.

Ao longo de todos os passos desse processo, houve, por parte dos envolvidos, uma severa preocupação com a qualidade, buscando evitar que ocorrências como conteúdo inadequado, contendo erros, de difícil compreensão, etc. fizessem com que o material não atendesse às suas necessidades de estudo.

Desta forma, fica claro que não é somente uma questão de fazer o que precisa ser feito, mas sim fazer de forma adequada, para que o resultado final seja algo que sirva e agregue valor a quem vai utilizá-lo. Esse é o valor da *qualidade*, algo que precisa ser gerenciado a cada momento, evitando desperdícios, reduzindo atrasos e gastos desnecessários, maximizando os benefícios para toda a sociedade.

É isso que você estudará aqui, com início na evolução histórica do processo da qualidade, abordando em seguida as normas relacionadas ao tema e, por último, o detalhamento do Prêmio Nacional da Qualidade para as organizações que buscam a excelência em seus processos de Qualidade. Bons estudos!

Para avançarmos no Controle Estatístico da Qualidade, é importante que, primeiramente, tenhamos muito bem fundamentado o que é a qualidade e como funciona a dinâmica de seu controle. Nesse contexto, não podemos interpretar o significado de “controle” como sendo algo relacionado a comando, domínio, poder, etc., mas sim de acompanhamento, monitoramento. Ou seja, certificar-se de que tudo está acontecendo a contento, ou seja, como deveria, como seria esperado e adequado.

Assim sendo, para que você, como cliente, receba um produto adequado, que atenda às suas necessidades, é importante que todos os passos sejam planejados, executados adequadamente e que tal execução seja continuamente acompanhada (“controlada”), de tal forma que, caso ocorra algum imprevisto, sejam tomadas ações de contorno e ajuste.



Figura 1.1: Cliente satisfeito: os clientes compram produtos e serviços que eles entendem serem capazes de atender às suas necessidades. Mas, para que isso seja possível, as empresas devem identificar quais são tais necessidades, desenvolver (criar) os produtos e serviços adequados para isso, produzi-los e entregá-los conforme as expectativas. Somente quando tal ciclo é completado, o cliente usufrui dos benefícios gerados pelo produto/serviço, tem suas necessidades atendidas e fica satisfeito.

Fonte: <https://pixabay.com/pt/experi%C3%A2ncia-do-cliente-melhor-3024488/>

O Controle da Qualidade faz parte, então, de um ciclo em que se monitoram as atividades relacionadas com o atendimento de necessidades dos clientes e da sociedade, garantido que tudo o que for necessário à adequação dos produtos e serviços ocorre da forma esperada.



Figura 1.2: O controle prevê que se saiba o que deve ser feito, que os passos façam parte de um planejamento, o qual serve de base para execução. E os resultados da execução são, então, controlados, ou seja, acompanhados, para verificar-se constantemente se estão alinhados com o que foi planejado.

Fonte: <https://pixabay.com/pt/verifique-gancho-marca-de-sele%C3%A7%C3%A3o-3183193/>

A lógica por trás desta sequência pode ser compreendida no exemplo de uma viagem: vamos supor que você decida fazer uma viagem para poder se inscrever pessoalmente em um concurso. Este é seu objetivo e, por conta dele é que você fará tal viagem. Você deverá planejá-la de tal forma que o objetivo possa ser alcançado: você vai decidir como vai

viajar (ônibus, carro, etc.) e quando isso ocorrerá. Como desdobramento de tais decisões, outras decisões deverão fazer parte do planejamento. Por exemplo, se for de ônibus, que dia e horário irá pegá-lo, quanto precisará levar de dinheiro para poder se alimentar durante a viagem e eventualmente para gastos quando chegar próximo ao destino (ônibus de linhas locais, táxi, etc.). E, obviamente, deverá, também, planejar seu retorno.



Figura 1.3: Planejando uma viagem. Por mais óbvio que seja, é importante ficar atento ao planejamento, de tal forma que possamos alcançar o objetivo que motivou a viagem. Assim, decidir como, quando, quanto gastaremos, que horas chegaremos, etc. são aspectos que devem nortear nossos planos.

Fonte: <https://pixabay.com/pt/mapa-navega%C3%A7%C3%A3o-m%C3%A3os-viagens-rota-455769/>

Uma vez que você tenha feito o planejamento, é hora de executar o que foi planejado, ou seja, viajar no dia, no horário e da forma prevista. No entanto, “fazer conforme o planejado” não garante 100% que o objetivo que motivou a viagem seja alcançado, afinal inúmeras variáveis podem criar perturbações. Por exemplo, uma greve de caminhoneiros ou de petroleiros pode causar atrasos diversos e mesmo cancelamentos de viagens. Assim, é necessário acompanhar o desenrolar dos fatos e tomar decisões com base no que acontece: por exemplo, se o horário do ônibus em que você marcou sua viagem foi cancelado, você deve remarcar sua viagem, mudar de companhia, optar por ir de carro, etc. Todas essas possíveis decisões representam mudanças no que foi originalmente planejado, ou

seja, ajustes cujo intuito é fazer com que você consiga contornar as dificuldades surgidas e chegar a tempo ao local em que fará sua inscrição, já que este é o objetivo.

Na produção de bens e na prestação de serviços, a lógica é a mesma: as empresas devem planejar seus processos de desenvolvimento de produtos e serviços, seu processo produtivo e logístico, de forma a fazer com que produtos e serviços adequados cheguem aos clientes e atendam às suas necessidades. No entanto, variáveis diversas durante a execução do que foi planejado, como aspectos não previstos no projeto, atraso na entrega de insumos por parte de fornecedores, bem como falta de energia, greves, atrasos ou extravios de cargas, etc. criam dificuldades diversas para o alcance do objetivo de atender aos clientes.

É necessário, assim, que os gestores estejam atentos à ocorrência e ao efeito de tais variáveis, de forma que tomem as decisões necessárias para garantir a continuidade e o sucesso no mercado. Parte das variáveis monitoradas está relacionada à qualidade, como a adequação dos insumos de produção, dos recursos produtivos, dos processos de trabalho, etc. Assim, as funções de controle da qualidade servem de instrumento de gestão, suportando decisões que garantirão que, apesar de barreiras, imprevistos e desvios, a trilha na direção do fornecimento de produtos e serviços adequados e que atendam às necessidades dos clientes seja mantida.

Evolução do processo da qualidade

Qualidade sempre foi um conceito implícito: os homens das cavernas sabiam que, se suas ferramentas não fossem adequadas, ou seja, feitas com material resistente, bem afiadas e bem fixadas, eles não teriam sucesso em suas caçadas. Quando iniciaram a agricultura, a lógica e a necessidade de “qualidade” permanecia: ferramentas e processos adequados para o plantio e a colheita, bem como para criação e abate de animais para alimentar suas famílias. Da mesma forma, é impensável que a evolução da raça permitisse construções sem que não houvesse qualidade em todos os processos envolvidos.



Figura 1.4: As sete maravilhas do mundo: a pirâmide de Gizé, os jardins suspensos da Babilônia, o templo de Ártemis, o farol da Alexandria, a estátua de Zeus, o mausoléu de Halicarnasso e o colosso de Rodas. Exemplos de obras que só se tornaram possíveis mediante a qualidade dos processos e recursos utilizados.

Fonte: https://www.shutterstock.com/pt/image-vector/seven-wonders-world-pyramid-giza-hanging-552267007?irgwc=1&utm_medium=Affiliate&utm_campaign=Hans%20Braxmeier%20und%20Simon%20Steinberger%20GbR&utm_source=44814&utm_term=

Mesmo quando a humanidade deixou de depender exclusivamente da agricultura e pecuária de subsistência, a qualidade manteve seu grau de importância. Por exemplo, um ferreiro em uma aldeia na Idade Média conhecia as necessidades de seus clientes. Ou seja, ele sabia quão resistentes deveriam ser as armaduras e os escudos, quão afiadas deveriam ser as espadas e lanças, como deveria ser a geometria das ferraduras para garantir o bom cavalgar dos cavalos, quão preciso deveria ser um mancal para livre giro das rodas das carruagens, etc. Conhecia, também, os materiais a serem utilizados, seus instrumentos e processos de trabalho, o que lhe permitia utilizá-los de forma correta e eficiente na produção de seus produtos, bem como garantia sua durabilidade.



Figura 1.5: Ofício do ferreiro. O conhecimento das necessidades e usos dos clientes, bem como o domínio do processo de trabalho e das ferramentas, garantia que a qualidade do que era produzido fosse a esperada para o sucesso de seu negócio.

Fonte: <https://pixabay.com/pt/ferreiro-fogo-ferro-carv%C3%A3o-brilho-2740128/>

O crescimento da demanda para o ferreiro era resolvido por meio de ajudantes (muitas vezes, filhos dele): o ferreiro ensinava seu ofício e acompanhava de perto a evolução de quem o auxiliava, garantindo, assim, que não houvesse perda de qualidade. Mas essa dinâmica tinha limites. Por exemplo, com o advento da Revolução Industrial, no final do século XVIII, e com o comércio organizado em grandes companhias, não havia mais condição de atender às enormes demandas de forma artesanal, nem era mais possível aos mestres do ofício acompanhar tantos auxiliares. Houve, assim, uma mudança significativa na estrutura do trabalho: os mestres se tornaram supervisores, procurando orientar, dentro do possível, o trabalho executado por inúmeros empregados e aprendizes. Faltava a muitos deles, porém, a experiência no ofício, a vivência para saber as necessidades dos clientes do que estava sendo produzido, bem como o conhecimento do processo como um todo. Por conta disso, os problemas apareciam.

Surge, assim, a necessidade de agilizar e facilitar o aprendizado, o que aconteceu como consequência da *administração científica*. Tendo Frederick Winslow Taylor (1856-1915) como seu grande expoente, a administração científica revolucionou os sistemas produtivos, avançando a produtividade a patamares inalcançáveis até então. Taylor

disseminou seus princípios em vários livros, como *Shop Management* (“Administração de oficinas”), de 1903, e *The Principles of Scientific Management* (“Princípios da administração científica”), de 1911 (JONES; GEORGE, 2011). Tais princípios consistiam basicamente nos seguintes elementos:

- desdobrar o trabalho, ou seja, dividi-lo em tarefas menores;
- compreender detalhadamente a forma como o trabalho ocorria em cada uma destas tarefas;
- buscar formas melhores de se desenvolver o trabalho, eliminando toda e qualquer atividade que não agregasse valor e agilizando as restantes;
- escolher o profissional com o perfil ideal para executar tais atividades;
- treinar a mão de obra, para executar as atividades laborais como estabelecido no estudo prévio;
- instaurar a supervisão, para garantir que os operários trabalhassem exatamente como o previsto e
- pagar por produção, de tal forma que os operários se esforçassem ao máximo para maximizar a produção e, assim, garantir maiores ganhos (ROCHA, 2017).

Ainda que tais iniciativas tenham maximizado a produção, o ritmo acelerado ao longo da cadeia produtiva era fonte de problemas de qualidade. E o foco da qualidade era a mera correção de desvios. A segmentação do trabalho em tarefas menores tornava tal situação ainda pior, visto que, ao contrário dos artesãos (como o ferreiro), que tinham conhecimento de todo o processo produtivo e das implicações de qualquer ação sobre o resultado final, os operários agora só conheciam a “sua parte do trabalho”.

Tentando minimizar esse tipo de problema, surgiu um novo tipo de atividade, a de inspeção. Tratava-se, de uma nova forma de divisão do trabalho: ao contrário do artesão, que produzia e avaliava a adequação do seu próprio trabalho, nessa nova configuração separava-se a atividade de produzir da atividade de avaliar. O intuito era utilizar a inspeção após a produção para, desta forma, evitar que produtos inadequados fossem enviados aos clientes, ou seja, separar o que estava ruim do que estava bom para comercialização e uso (PALADINI, 1994). Na verdade, desentendimentos entre compradores e fabricantes levavam a uma inspeção completa (100%) dos lotes produzidos.

Assim, a lógica de estabelecer a melhor forma de produzir e garantir que os operários seguissem fielmente tais passos se expandia, agora, para a inspeção do que ele fazia: inspetores eram treinados para verificar se o que foi produzido era adequado (mesmo que o inspetor não tivesse a visão e compreensão do todo).

Apesar disso, alguns problemas persistiam (e novos problemas até mesmo surgiram): a inspeção completa do lote inseria um custo adicional (o custo de inspeção), sem que, de fato, o produto se tornasse melhor (ou tivesse mais qualidade). Você pode se perguntar: mas, como não, se, assim, evitamos que produtos defeituosos saiam da empresa? A resposta é que, sim, realmente havia um “filtro” para reter tais produtos. Mas os produtos “bons”, ou seja, os que não tinham qualquer tipo de problema, não se tornavam melhores (ou tinham mais qualidade) por terem passado pela inspeção. Lembre-se que inspetores aumentam os custos e não produzem – eles só existem porque os defeitos existem (PARANTHAMAN, 1990). Assim, ao contrário das atividades de produção, que agregavam valor ao que estava sendo produzido, a inspeção nada agregava, sendo somente um gasto (ainda que pudesse evitar danos maiores, por reter produtos inadequados).

Além do aumento no custo da operação (sem correspondente aumento no valor agregado aos produtos), a adição da atividade de inspeção acrescentava tempo ao processo de produção, fazendo com que os produtos demorassem mais até chegar aos consumidores e, conseqüentemente, aumentasse o tempo para as empresas receberem por suas vendas. A propósito, com o aumento da velocidade de produção, a inspeção 100% manual se torna impossível. Mesmo quando a inspeção auxiliava a empresa a evitar que produtos defeituosos seguissem para o mercado, isso acontecia de forma tardia: os altos volumes de produção (normalmente em grandes lotes) faziam com que grandes quantidades de produtos fossem produzidas antes de serem enviadas para inspeção. Assim, caso fosse detectado algum problema mais sério, normalmente inerente ao processo produtivo, provavelmente todo o lote, ou seja, tudo o que fora produzido até o momento da inspeção, estaria comprometido, gerando retrabalho ou mesmo sucateamento dos produtos produzidos.

Além disso, não podemos esquecer que a inspeção em si, por se tratar de um processo, era passível de erros. Por exemplo, ainda que fosse uma inspeção de 100%, existia o risco de falhas nesse processo, o que faria com que produtos inadequados fossem aprovados, bem como produtos adequados, rejeitados. E as oportunidades de melhoria do processo

acabavam sendo escassas: primeiramente pela limitação da visão do todo e, em seguida, pelo fato de que o controle da qualidade se limitava à inspeção, contagem, classificação pela qualidade e a reparos, sem foco na identificação das causas-raiz dos problemas. Inspetores aceitavam ou rejeitavam os produtos somente, isto é, verificavam se materiais, peças, componentes, ferramentas e outros elementos envolvidos no processo estavam de acordo com os padrões estabelecidos.

Tal cenário persistiu até o século XX. Em 1924, a Western Electric criou um Departamento de Engenharia e Inspeção, definindo as bases para o que posteriormente foi o Departamento de Garantia da Qualidade da Bell Telephone Laboratories. Deste grupo, fizeram parte, dentre outros, Walter Andrew Shewhart (1891-1967), William Edwards Deming (1900-1993) e Joseph Moses Juran (1904-2008), conhecidos “gurus da qualidade”. Foi também em 1924 que Shewhart propôs o uso do gráfico de controle para a análise de dados resultantes de inspeção (RAMOS et al., 2013), fazendo com que a importância dada à inspeção começasse a ser substituída por uma ênfase no estudo e prevenção dos problemas relacionados à qualidade.

Em 1931, Shewhart publicou a obra *Economic Control of Quality of Manufactured Product*, que conferia um caráter científico à disciplina (COSTA et al., 2004). A lógica de tal pensamento era bastante interessante: ao invés de uma inspeção “no final”, quando os lotes já estavam produzidos, haveria uma forma de inspeção constante, mas que, ao invés de limitada a aprovar x rejeitar, representasse um acompanhamento do processo, buscando identificar mudanças que ocorressem. Reconhecia-se, assim, a variabilidade do processo como fator importante de qualidade. Ou seja, se os produtos estivessem sendo produzidos inicialmente de maneira adequada e alcançando qualidade aceitável, havia a expectativa de que assim continuassem enquanto nada no processo fosse modificado. Uma vez que alguma mudança fosse detectada, não seria mais possível “confiar” na qualidade dos produtos: a causa da mudança deveria ser investigada, para se aferir se os produtos continuavam aceitáveis ou não. Desta forma, alertas de risco de confecção de produtos inaceitáveis (ou seja, possivelmente rejeitados na inspeção posterior) ocorriam antecipadamente, com base em mudanças detectadas nos processos.

Membros do mesmo grupo, na Bell Telephone Laboratories, Harold French Dodge (1893-1976) e Harry Gutelius Romig (1874-1948) estudavam a prática da amostragem e desenvolveram os conceitos básicos de amostragem para aceitação, o segundo elemento crítico no crescimento

do controle estatístico da qualidade: para se identificar uma eventual mudança no processo, não havia a necessidade de inspecionar 100%. Amostras coletadas de forma estruturada (por meio do uso da estatística para definir a quantidade e a frequência de coleta) seriam suficientes para identificar variações, e, assim, o controle de processo passou a ser feito com base nos princípios da probabilidade e da estatística.

A junção do acompanhamento dos resultados dos processos com a prática das medidas por amostragem compôs o que é chamado de controle estatístico da qualidade (CEQ) ou controle estatístico de processos (CEP). Sua utilização permitiu contornar diversas limitações existentes na inspeção 100%:

- A prática da amostragem reduzia os custos proibitivos da inspeção 100%, além de praticamente eliminar os impactos de tempo, visto que as amostras eram usualmente uma pequena fração do volume produzido. Mesmo a produção de altos volumes representa uma quantidade relativamente pequena de unidades a serem avaliadas no CEQ.
- Além disso, a coleta e o acompanhamento dos resultados eliminavam o problema de alertas tardios: variações detectadas eram o sinal de alerta e de início da busca para identificação das causas. Com isso, prevenia-se a produção de grandes quantidades até que se detectasse um problema que poderia exigir custoso retrabalho ou descarte de produtos já produzidos.
- A pesquisa para identificar as causas de variação eliminava, também, o problema referente ao desconhecimento sobre o processo em si e suas implicações no sistema produtivo como um todo: identificar o que mudou no processo, como isso ocorre e seus efeitos faz com que os envolvidos aprendam mais sobre o processo em si, permitindo identificar oportunidades de melhoria.
- A própria vulnerabilidade do processo de inspeção, que poderia levar a erros, isto é, aprovar produtos sem a qualidade necessária e/ou rejeitar produtos aceitáveis, era praticamente resolvida pelo uso do CEQ: tais erros seriam identificados como variações, ou seja, algo diferente do que vinha acontecendo regularmente (por exemplo, uma rejeição em meio a amostras aprovadas), o que dispararia o processo de investigação. Tal investigação levaria a identificar eventuais problemas ocorridos na inspeção em si.

Segundo Feigenbaum (1994), Gonçalves (1995), Machado Jr. e Rotondaro (2003), Santos (2008) e Xanthopoulos (2009), o CEQ teve forte impulso na Inglaterra, quando, em 1935, surgiram normas específicas relacionadas ao controle da qualidade (British Standard BS 600), ao que se seguiram diversos padrões e normas durante o período da Segunda Guerra Mundial, incluindo, em 1942, uma seção de controle da qualidade no Departamento de Guerra dos Estados Unidos, que criou um conjunto de tabelas de amostragem baseadas no conceito de Níveis de Qualidade Aceitáveis (NQA) para o produto.

De acordo com os autores, as práticas de Controle da Qualidade continuavam a se expandir durante e após a guerra: em 1944, é editada a primeira publicação sobre o assunto, a *Industrial Quality Control*; em 1945, é formada a Sociedade dos Engenheiros da Qualidade e, um ano depois, a Sociedade Americana de Controle de Qualidade – ASQC (sigla em inglês), mesmo ano em que foi criada a Union of Japanese Scientists and Engineers (JUSE), uma organização constituída por engenheiros e pesquisadores, estabelecida com o objetivo de promover estudos sistemáticos necessários para o avanço da ciência e tecnologia, contribuindo assim para o desenvolvimento da cultura e da indústria (JUSE, 2015).

A criação da JUSE coincidiu com o início das ações das forças de ocupação americanas no Japão para implantação de um programa eficiente de controle da qualidade, com o objetivo de eliminar os defeitos e a falta de uniformidade na qualidade dos equipamentos produzidos pela indústria japonesa. Em 1947, Deming integrou tal grupo, recrutado pelo general MacArthur para prestar colaboração às forças americanas.



Segunda guerra mundial

Paradoxalmente, as guerras, além da destruição causada, usualmente trazem desenvolvimento tecnológico e empresarial substancial. A busca por meios de produção mais eficientes, que permitam produzir em grande volume armamentos e equipamentos militares foi percebida ao longo do século passado, bem como o surgimento da pesquisa operacional como hoje conhecemos (CORREA, 2003). A própria logística tem forte fundamento nas ações e movimentações militares.

Em especial, a partir da Segunda Guerra Mundial, muitas das tecnologias que hoje fazem parte de nosso dia a dia, como o radar, o forno de micro-ondas, computadores, etc., foram viabilizadas. E, desde então, o que se vê é uma via de mão dupla, em que não somente a sociedade civil se beneficia das tecnologias desenvolvidas pelos militares, mas o inverso também ocorre (DUARTE, 2012).

Apesar de alguns especialistas japoneses já estudarem as técnicas estatísticas, estas eram pouco aplicadas devido a um excessivo apelo na forma matemática complexa, o que dificultava sua adoção. Assim, havia pouco interesse dos gestores das empresas pelo controle de qualidade, que se configurava como um movimento de engenheiros e operários. Permanecia, desta forma, uma qualidade baseada quase que exclusivamente na inspeção, e os altos volumes produzidos a baixo custo tinham uma qualidade sofrível e inaceitável para as exigências do mercado internacional (algo totalmente diferente do cenário atual, em que produtos japoneses são exemplo de qualidade). Assim, a ação americana foi um marco, pois, o denominado “método americano de qualidade” começou a ser ensinado, disseminado e aplicado no Japão, sendo utilizado por empresas de diversos setores da economia.

Em 1949, a JUSE formou o grupo de pesquisa do controle de qualidade, cujos membros trabalhavam em universidades, indústrias e órgãos governamentais. Este grupo tinha como objetivos pesquisar e disseminar os conhecimentos sobre o controle da qualidade, para que as indústrias japonesas pudessem melhorar a qualidade de seus produtos e aumentar os níveis de exportação. Fazia parte deste grupo o engenheiro Kaoru Ishikawa (1915-1989).

Em 1950, a JUSE trouxe Deming para proferir um seminário sobre controle de qualidade para administradores e engenheiros, abordando a importância do entendimento da variabilidade presente em todos os processos de produção de bens e serviços e os consequentes benefícios da utilização de gráficos de controle para o gerenciamento de processos. Discutiu, também, a utilização do Ciclo PDCA (Plan-Do-Check-Act) – que será discutido em profundidade na Aula 2 – para a melhoria da qualidade, mas, principalmente, nesse e em outros seminários subse-

quentes, foi explicado o papel que a alta administração deveria desempenhar para a implantação e o desenvolvimento das atividades do controle da qualidade.

Os 14 pontos de Deming (2000):

1. crie uma constância de propósitos para melhoria dos produtos e serviços;
2. adote a nova filosofia;
3. cesse a dependência da inspeção para alcançar a qualidade;
4. minimize o custo total trabalhando com um único fornecedor: acabe com a prática de realizar negócios baseados somente nos preços;
5. melhore, constante e continuamente, cada processo;
6. institua o treinamento na tarefa;
7. adote e institua a liderança;
8. jogue fora os receios;
9. quebre as barreiras entre as áreas;
10. elimine slogans, exortação e cartazes para a força de trabalho;
11. elimine cotas numéricas para a força de trabalho e objetivos numéricos para o gerenciamento;
12. remova as barreiras que roubam das pessoas a satisfação no trabalho;
13. institua um vigoroso programa de educação e automelhoria para todos;
14. coloque todos na companhia para trabalhar, acompanhando a transformação.

A partir deste ponto, o controle de qualidade no Japão deixa de ser visto como uma atividade essencialmente técnica, para ser percebido e utilizado como uma ferramenta de gestão, a principal característica do que se entende hoje como sendo o controle da qualidade total (TQC – Total Quality Control), ainda que o termo TQC só tenha sido utilizado pela primeira vez por Armand Feigenbaum em 1957, que o definiu como um sistema que propiciava a satisfação dos clientes, provendo os produtos ou serviços de forma econômica, com a participação de todos os empregados da organização, que contribuíam para o desenvolvimento, manutenção e melhoria de qualidade de forma global. Tais

esforços envolviam a engenharia do produto e do processo, marketing, produção, inspeção e expedição, além, obviamente, da gestão. O princípio a ser reconhecido é o de que qualidade é um trabalho de todos, onde o controle inicia no projeto do produto e permanece até o produto chegar ao cliente satisfeito (FEIGENBAUM, 1994).

Juran foi, também, peça-chave nessa expansão do TQC, reforçando a ideia do controle de qualidade como ferramenta gerencial, sendo considerado o responsável pela transformação da gerência japonesa de alto e médio níveis por volta de 1954, defendendo o lema “administrar para a qualidade” como mote do envolvimento da alta administração. Apontou que o gerenciamento para a qualidade envolvia três processos básicos gerenciais (a denominada Trilogia de Juran) (JURAN, 1991):

Planejamento da qualidade:

1. Identifique os consumidores.
2. Determine as suas necessidades.
3. Crie características de produto que satisfaçam essas necessidades.
4. Crie os processos capazes de satisfazer essas características.
5. Transfira a liderança desses processos para o nível operacional.

Controle de qualidade:

1. Avalie o nível de desempenho atual.
2. Compare-o com os objetivos fixados.
3. Tome medidas para reduzir a diferença entre o desempenho atual e o previsto.

Melhoria da qualidade:

1. Reconheça as necessidades de melhoria.
2. Transforme as oportunidades de melhoria numa tarefa de todos os trabalhadores.
3. Crie um conselho de qualidade, selecione projetos de melhoria e as equipes de projeto e facilitadores.
4. Promova a formação em qualidade.

5. Avalie a progressão dos projetos.
6. Premie as equipes vencedoras.
7. Faça publicidade dos seus resultados.
8. Reveja os sistemas de recompensa para aumentar o nível de melhorias.
9. Inclua os objetivos de melhoria nos planos de negócio da empresa.

Mudava, assim, o foco exclusivo nos aspectos tecnológicos das fábricas para os aspectos do gerenciamento de toda a organização. Não houve, de fato, uma transição do CEQ para o TQC, até porque, para realizar o TQC, é importante levantar as causas dos problemas utilizando métodos estatísticos: na realidade, o CEQ foi incorporado por algo mais amplo, envolvendo a participação de todos os setores e de todos os empregados da empresa. Para isso, a cultura japonesa da disciplina, respeito aos superiores, colaboração participativa e busca pela excelência foi elemento que facilitou a implantação das mudanças e a forte avançagem dos resultados.

A noção do envolvimento de todos na empresa pela qualidade serviu de base para que, em conjunto com a JUSE, Ishikawa introduzisse o conceito de círculos de controle de qualidade (CCQ), em 1962. Ishikawa é reconhecido como o responsável pela adequação do TQC à cultura japonesa e, também, pela massificação de ferramentas de qualidade para uso de todos, tendo como fundamento educar todas as pessoas que trabalhavam nas fábricas japonesas em técnicas estatísticas: as denominadas sete ferramentas da qualidade.

Embora algumas dessas ferramentas já fossem conhecidas há tempos, Ishikawa as organizou, visando aperfeiçoar o TQC. O próprio diagrama de causa e efeito (ou diagrama “espinha de peixe”, que faz parte das Normas Industriais Japonesas – JIS (sigla em inglês), sendo aplicado em diversas áreas) foi criado por ele em 1943, razão pela qual é conhecido também como diagrama de Ishikawa (RAMOS et al., 2013). As sete ferramentas de Ishikawa são:

1. gráfico de Pareto;
2. folhas de verificação;
3. fluxogramas;
4. diagrama de causa-efeito;
5. histogramas;

6. gráfico de dispersão;
7. cartas de controle.

Também na mesma época, Shigeo Shingo (1909-1990) associou as ferramentas e conceitos da qualidade com a produtividade, sendo conceitos com íntima relação, visto que não há produtividade sem qualidade e vice-versa. Assim, no período de 1961-64, Shingo estendeu as ideias de controle de qualidade e desenvolveu o Poka-yoke (dispositivo a prova de erros, que impede erros nos processos produtivos ou no uso dos produtos), com forte viés em uma estratégia para a melhoria contínua através do envolvimento criativo de todos os trabalhadores (ROSSATO, 1996; SALVIATO, 1999). No TQC, predomina o uso intensivo de ferramentas diversas: além das sete ferramentas de Ishikawa, são também utilizadas o FMEA (Failure Mode and Effect Analysis), QFD (Quality Function Deployment), o PDCA (Plan-Do-Check-Act), dentre outras.

A expansão desse movimento ao longo dos anos trouxe nas últimas décadas do século XX um novo termo, a Gerência da Qualidade Total (TQM – Total Quality Management), que engloba gerenciar a eficácia e eficiência de todos os elementos, internos e externos à empresa. Compreende, assim, o gerenciamento das relações entre todos os envolvidos com a existência da empresa, não se restringindo somente ao relacionamento com o cliente. Desta forma, além dos elementos, ferramentas, práticas e modelos existentes no TQC fazem parte, também, da TQM, mas esta vai além, trabalhando aspectos como gestão estratégica e corporativa, governança, relacionamento com fornecedores, preocupações com a qualidade de vida de todos e o bem-estar da sociedade, objetivando a sobrevivência da empresa e sua competitividade global. Ou seja, “um conjunto de ações que possibilitam administrar a organização com esforço na qualidade em todos os setores, em todas as pessoas, em todos os processos” (ROCHA, 2010, p. 32). A gestão da qualidade é entendida como uma extensão das práticas e conceitos anteriores, como um sistema de gerenciamento não mais do domínio de especialistas, mas de responsabilidade de todas as áreas. Na verdade, é correto pensarmos no TQC como sendo uma parte do TQM, ainda que alguns autores confundam os termos, pelo fato de ambos desenvolverem atividades similares (ROCHA, 2010).

Como forma de garantir a continuidade de atividades, o sucesso e a lucratividade, as empresas começaram a dar mais atenção ao mercado e à concorrência, priorizando a qualidade do ponto de vista do cliente. O

TQM prevê requisitos claros e mensuráveis para transações, educação e treinamento contínuos, atenção aos relacionamentos e envolvimento dos gestores para melhoria contínua, com a qualidade colocada como ponto central dos negócios. Surgem, então, análises dos custos do ciclo de vida dos produtos, incluindo gastos com garantia, atendimento e manutenção ao longo do tempo e os gerentes passam a se preocupar em melhorar continuamente, com o envolvimento e compromisso de todos, o treinamento e a formação de equipes (CAMPOS, 2004).

Consequentemente, a responsabilidade pela qualidade migra do nível operacional para o tático, e chega ao estratégico. O foco na gestão trouxe novas abordagens, como a segregação de custos de qualidade como inevitáveis (voltados à prevenção, como inspeção, amostragem, etc.) e evitáveis (como consequência de defeitos e falhas, isto é, retrabalho, sucateamento, etc.), que são caracterizados por Crosby (1979) como custos de não conformidade. Para o autor, os custos envolvidos quando a qualidade não é alcançada são maiores que os custos para gerá-la, sendo, portanto, um bom investimento a ser feito. Philip Bayard Crosby (1926-2001) defendeu o conceito de “zero defeito”, ou seja, a ideia de que a ausência de defeitos deveria ser o padrão de desempenho dos sistemas de gestão e, assim, a qualidade perfeita seria não só tecnicamente possível como também economicamente desejável, ao buscar-se “fazer certo na primeira vez”, com todas as pessoas envolvidas nos processos executando corretamente as tarefas. Desta forma, os defeitos deveriam ser antecipados e evitados, e não contabilizados.

Tal abordagem foi ampliada por Genichi Taguchi (1924-2012), ao defender que qualquer desvio do ideal, da perfeição, faria com que o produto fosse um gerador de perdas para a sociedade, fossem na forma de retrabalhos, garantias, devoluções ou substituições. Reduzir as perdas não estaria, então, relacionado somente à conformidade com as especificações, mas sim à redução das variações, o que reforça a importância do CEQ.

Importante destacar que a diferença entre a abordagem do início do século XX e a atual é que a qualidade agora está relacionada às necessidades e aos anseios dos clientes. Nesse sentido, Tom Peters (1942-) aponta que a excelência nos negócios depende de oito ingredientes (PETERS; WATERMAN, 1982):

1. A pró-atividade com incentivo às pessoas para melhorar o que se está fazendo através de uma fórmula de ensaio e erro: “fazem, con-

sertam e tentam fazer melhor”.

2. Aprender com os clientes. Empresas excelentes “aprendem com as pessoas que a estão servindo”.
3. Estimular a independência promovendo o empreendedorismo e a autonomia dos colaboradores.
4. Gestão se aprende gerindo. Só fazendo se é possível aprender algo novo e capaz de movimentar a empresa no caminho da excelência.
5. Produtividade só se alcança com trabalhadores motivados e produtivos, portanto eles são avaliados como peças-chave para o sucesso.
6. Foco. Empresas excelentes se atêm às suas competências, e não saem atirando para todos os lados.
7. Simplicidade. Manter a forma simples e a equipe, a mais enxuta possível.
8. Mobilidade. As empresas excelentes podem sair de um formato compacto para a expansão rapidamente, adequando-se às necessidades do mercado e dos clientes.

Da mesma forma, David Alan Garvin (1952-2017) identificou oito dimensões básicas da qualidade dos produtos, quais sejam (GARVIN, 1984; 2002):

1. desempenho (*performance*): características primárias de um produto. Por exemplo, em um automóvel seriam a aceleração, a velocidade final, o nível de conforto, etc.;
2. características acessórias (*features*): são os adicionais, os detalhes, o supérfluo que valoriza o produto, como um brinde recebido, o volante regulável no automóvel, a simpatia na recepção do hotel, etc.;
3. confiabilidade (*reliability*): probabilidade de o produto funcionar sem falhas durante determinado período de tempo, executando todas as funções que são esperadas dele, como, por exemplo, um automóvel que possa ser usado para transportar pessoas e bagagem em segurança, sem barulhos indesejados, com razoável nível de conforto, etc., sem problemas de manutenção;
4. conformidade (*conformance*): diz respeito ao grau em que as peças executadas correspondem ao projeto. Tal dimensão possibilita ganhos de produtividade, redução de trabalho, diminuição de custos. É o “fazer certo, da primeira vez”, o que é esperado. Ou seja,

não é ser melhor ou pior, mas sim estar conforme. Por exemplo, nesta dimensão, uma Ferrari e um veículo popular possivelmente têm o mesmo nível de qualidade;

5. durabilidade (*durability*): é a medida da vida do produto, bastante ligada à confiabilidade e muito valorizada em diversos tipos de produtos;
6. atendimento (*serviceability*): refere-se à velocidade, cortesia e competência nos serviços de pós-vendas. Devemos entender o pós-venda como um conjunto de ações e atividades que dão continuidade ao atendimento das necessidades dos consumidores. Ou seja, a relação cliente-empresa-produto não é encerrada com o ato da venda do produto: ela deve continuar e com qualidade;
7. aparência (*aesthetics*): é a percepção (normalmente visual, podendo ser, também tátil ou mesmo auditiva, gustativa ou olfativa) do cliente sobre o produto, sendo uma dimensão de difícil mensuração, bastante subjetiva, sendo um julgamento pessoal e reflexo das preferências individuais; e
8. qualidade percebida (*perceived quality*): a mais subjetiva das dimensões, combina elementos e fatores diversos, como aparência, boca a boca, marca, publicidade, reputação, robustez, similaridade com outros produtos, tradição, etc. Corresponde à situação em que o cliente acredita que determinado produto tenha boa qualidade.

Como você pode perceber, houve um longo caminho evolutivo da qualidade. E há ainda muito espaço para inovações, aperfeiçoamentos e refinamentos de suas práticas e ferramentas, junto à preocupação com padronizações.

Normalização

A Associação Brasileira de Normas Técnicas – ABNT (2014) define normalização como sendo:

Atividade que estabelece, em relação a problemas existentes ou potenciais, prescrições destinadas à utilização comum e repetitiva com vistas à obtenção do grau ótimo de ordem em um dado contexto. Consiste, em particular, na elaboração, difusão e implementação das Normas.

A normalização é, assim, o processo de formulação e aplicação

de regras para a solução ou prevenção de problemas, com a cooperação de todos os interessados, e, em particular, para a promoção da economia global. No estabelecimento dessas regras recorre-se à tecnologia como o instrumento para estabelecer, de forma objetiva e neutra, as condições que possibilitem que o produto, projeto, processo, sistema, pessoa, bem ou serviço atendam às finalidades a que se destinam, sem se esquecer dos aspectos de segurança.

Norma é o documento estabelecido por consenso e aprovado por um organismo reconhecido, que fornece regras, diretrizes ou características mínimas para atividades ou para seus resultados, visando à obtenção de um grau ótimo de ordenação em um dado contexto.

A norma é, por princípio, de uso voluntário, mas quase sempre é usada por representar o consenso sobre o estado da arte de determinado assunto, obtido entre especialistas das partes interessadas.

De acordo com Gehlen (2018b), no Brasil, qualquer pessoa ou organização pode solicitar à ABNT a criação de uma nova norma ou a tradução de uma norma internacional. A solicitação é incluída no programa de normalização e um comitê é criado para avaliar a solicitação. Caso positivo, é elaborado o projeto da norma, com consulta às partes interessadas. Uma vez aprovada, a norma é inserida no catálogo de normas da ABNT (que pode ser acessado pelo link <http://www.abnt.org.br/normalizacao/abnt-catalogo>), tornando-se disponível para uso, como mostrado na **Figura 1.6**.

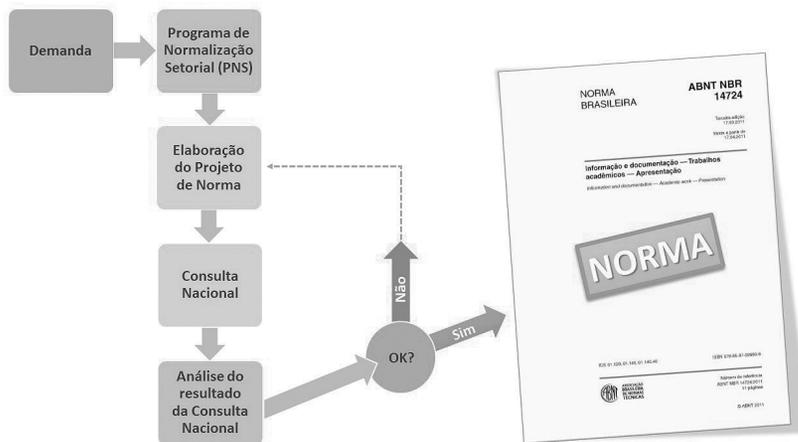


Figura 1.6: Fluxo de elaboração de normas. A partir da demanda, o tema é discutido amplamente, até atingir consenso. É gerado um Projeto de Norma, o qual será submetido à Consulta Nacional, com ampla divulgação, dando assim oportunidade a todas as partes interessadas de examiná-lo e emitir suas considerações. As sugestões aceitas são consolidadas no Projeto de Norma, que é homologado e publicado pela ABNT.

Fonte: <http://www.abnt.org.br/normalizacao/elaboracao-e-participacao/como-se-elaboram>

As normas, de acordo com a ABNT (2014), “asseguram as características desejáveis de produtos e serviços, como qualidade, segurança, confiabilidade, eficiência, intercambialidade, bem como respeito ambiental – e tudo isto a um custo econômico” e objetivam:

- tornar o desenvolvimento, a fabricação e o fornecimento de produtos e serviços mais eficientes, mais seguros e mais limpos;
- facilitar o comércio entre países, tornando-o mais justo;
- fornecer aos governos uma base técnica para saúde, segurança e legislação ambiental, bem como para avaliação da conformidade;
- compartilhar os avanços tecnológicos e a boa prática de gestão;
- disseminar a inovação;
- proteger os consumidores e usuários, em geral, de produtos e serviços, e
- tornar a vida mais simples, provendo soluções para problemas comuns.

Como entidade de destaque em termos de normalização global, existe a ISO (Internacional Organization for Standardization), uma organização não governamental, fundada em 23 de fevereiro de 1947, com sede em Genebra (Suíça), que elabora normas de aplicação internacional em

todos os campos do conhecimento. Mais de 100 países participam da ISO (+95% da produção industrial do mundo) e, no Brasil, a participação se dá por meio da ABNT. O processo de normalização brasileira segue a estrutura hierárquica SINMETRO → CONMETRO → CBN → ABNT (INMETRO, 2012), em que:

SINMETRO – Sistema Nacional de Metrologia, Normalização e Qualidade Industrial: organismo máximo do qual emanam as decisões sobre as atividades de normalização no Brasil;

CONMETRO – Conselho Nacional de Metrologia, Normalização e Qualidade Industrial: órgão normativo do SINMETRO;

CBN – Comitê Brasileiro de Normalização: comitê assessor do CONMETRO nos assuntos relativos à normalização;

ABNT – Associação Brasileira de Normas Técnicas: responsável pela área de normalização dentro do SINMETRO, sendo, também, a representante do Brasil junto aos organismos internacionais de normalização.

O objetivo da ISO é fixar normas técnicas de alcance internacional de maneira a favorecer as relações econômicas entre os países, tendo como missão a promoção do desenvolvimento da normalização e atividades correlatas no mundo, com a visão de facilitar o intercâmbio internacional de bens e serviços e de desenvolver a coordenação nas esferas de atividade intelectual, científica, tecnológica e econômica.

Especificamente na área de qualidade, a norma de grande destaque é a da série 9000 (Sistema de Gestão da Qualidade), cuja primeira versão foi publicada em 1987, com revisões em 1994, 2000, 2008 e 2015. O sumário da norma certificável ISO 9001:2015, referente a Sistemas de Gestão da Qualidade, para empresas industriais e prestadoras de serviços, é mostrado a seguir:

Quadro 1.1: Requisitos da norma ISO 9001:2015

Item	Requisito Normativo
Introdução	
0.1	Generalidades
0.2	Princípios de Gestão da Qualidade
0.3	Abordagem de processo
0.3.1	Generalidades

0.3.2.	Ciclo Plan – Do – Check - Act
0.3.3	Mentalidade de Risco
0.4	Relacionamento com outras Normas de sistemas de gestão
1	Escopo
2	Referência Normativa
3	Termos e definições
4	Contexto da Organização
4.1	Entendendo a organização e seu contexto
4.2	Entendendo as necessidades e expectativas de partes interessadas
4.3	Determinando o escopo do sistema de gestão da qualidade
4.4	Sistema de Gestão da Qualidade e seus processos
5	Liderança
5.1	Liderança e Comprometimento
5.1.1	Generalidades
5.1.2	Foco no cliente
5.2	Política
5.2.1.	Desenvolvendo a Política da Qualidade
5.2.2	Comunicando a Política da Qualidade
5.3	Papéis, responsabilidades e autoridades organizacionais
6	Planejamento
6.1	Ações para abordar riscos e oportunidades
6.2	Objetivos da qualidade e planejamento para alcançá-los
6.3	Planejamento de mudanças
7	Apoio
7.1	Recursos
7.1.1	Generalidades
7.1.2	Pessoas
7.1.3	Infraestrutura
7.1.4	Ambiente para operação dos processos
7.1.5	Recursos de monitoramento e medição
7.1.5.1	Generalidades
7.1.5.2	Rastreabilidade de medição
7.1.6	Conhecimento organizacional
7.2	Competência
7.3	Conscientização

7.4	Comunicação
7.5	Informação documentada
7.5.1	Generalidades
7.5.2	Criando e atualizando
7.5.3	Controle de informação documentada
8	Operação
8.1	Planejamento e controle operacionais
8.2	Requisitos para produtos e serviços
8.2.1	Comunicação com o cliente
8.2.2	Determinação de requisitos relativos a produtos e serviços
8.2.3	Análise crítica de requisitos relativos a produtos e serviços
8.2.4	Mudanças nos requisitos para produtos e serviços
8.3	Projeto e desenvolvimento de produtos e serviços
8.3.1	Generalidades
8.3.2	Planejamento de projeto e desenvolvimento
8.3.3	Entradas de projeto e desenvolvimento
8.3.4	Controles de projeto e desenvolvimento
8.3.5	Saídas de projeto e desenvolvimento
8.3.6	Mudanças de projeto e desenvolvimento
8.4	Controle de processos, produtos e serviços providos externamente
8.4.1	Generalidades
8.4.2	Tipo e extensão do controle
8.4.3	Informação para provedores externos
8.5	Produção e provisão de serviço
8.5.1	Controle de Produção e de provisão de serviço
8.5.2	Identificação e rastreabilidade
8.5.3	Propriedade pertencente a clientes ou provedores externos
8.5.4	Preservação
8.5.5	Atividades Pós-entrega
8.5.6	Controle de mudanças
8.6	Liberação de Produtos e serviços
8.7	Controle de saídas não conformes
9	Avaliação de desempenho
9.1	Monitoramento, medição, análise e avaliação
9.1.1	Generalidades

9.1.2	Satisfação do cliente
9.1.3	Análise e Avaliação
9.2	Auditoria Interna
9.3	Análise crítica pela direção
9.3.1	Generalidades
9.3.2	Entradas de análise crítica pela direção
9.3.3	Saídas de Análise crítica pela direção
10	Melhoria
10.1	Generalidades
10.2	Não conformidade e ação corretiva
10.3	Melhoria continua

Fonte: Adaptado de ABNT (2015)

A ISO 9001:2015 (ABNT, 2015) especifica requisitos para um sistema de gestão da qualidade quando uma organização: a) necessita demonstrar sua capacidade para prover consistentemente produtos e serviços que atendam aos requisitos do cliente e aos requisitos estatutários e regulamentares aplicáveis, e b) visa aumentar a satisfação do cliente por meio da aplicação eficaz do sistema, incluindo processos para melhoria do sistema e para a garantia da conformidade com os requisitos do cliente e com os requisitos estatutários e regulamentares aplicáveis.

Como você pode verificar no **Quadro 1.1**, aborda diversos tópicos relacionados ao controle da qualidade/CEQ, em especial, os itens 9.1. (Monitoramento, medição, análise e avaliação) e 10.2. (Não conformidade e ação corretiva). Direcionamentos como: “A organização deve [...] determinar e aplicar os critérios e métodos (incluindo monitoramento, medições e indicadores de desempenho relacionados) necessários para assegurar a operação e o controle eficazes desses processos” (item 4.4); “A organização deve assegurar que saídas que não estejam conformes com seus requisitos sejam identificadas e controladas para prevenir seu uso ou entrega não pretendido” (item 8.7); “A organização deve determinar: a) o que precisa ser monitorado e medido; b) os métodos para monitoramento, medição, análise e avaliação necessários para assegurar resultados válidos; c) quando o monitoramento e a medição devem ser realizados” (item 9.1.1) e “A organização deve analisar e avaliar dados e informações apropriados, provenientes de monitoramento e medição” (item 9.1.3) também evidenciam tais focos.

Outras normas relevantes são descritas a seguir (FSC, [201-?]; FUNDAÇÃO VANZOLINI, s.d.; GEHLEN, 2018a):

- IATF 16949:2016 (que substitui a norma ISO/TS 16949, de sistemas de qualidade automotiva dentro da indústria automotiva global e era específica para a cadeia automobilística, incluindo montadoras, sistemistas e fornecedores em todos os níveis): exige o cumprimento de vários requisitos novos e/ou revisados específicos da indústria automotiva. Referencia a ISO 9001:2015 e respeita toda sua estrutura e requisitos, não sendo utilizada isoladamente, mas sempre como um suplemento e em conjunto com a ISO 9001:2015;
- ISO 14001:2015: Esta certificação atesta que a empresa tem uma atitude ambientalmente correta, controlando seus impactos ambientais e prevenindo a geração de poluição. Com ela, a empresa obtém vantagens competitivas como a minimização de custos, evitando taxas e paradas de produção atualmente impostas às empresas poluidoras. É complementar às normas ISO 14004 (Diretrizes gerais sobre princípios, sistemas e técnicas de apoio); ISO 14005 (Guia para a implementação em fases de um sistema de gestão ambiental para facilitar sua adoção por pequenas e médias empresas); ISO 14006 (Norma para ECO-DESIGN); ISO 14015 (Sistema de gestão ambiental – Avaliações ambientais de localidades e organizações); ISO 14020 (Conjunto de normas que tratam de selos ambientais); ISO 14021 (Autodeclarações ambientais – Rótulo ambiental tipo II); ISO 14024 (Rótulo ambiental tipo I); ISO 14031 (Guia para avaliação de desempenho ambiental – Diretrizes); ISO 14033 (Diretrizes e exemplos para compilar e comunicar informações ambientais quantitativas); ISO 14040 (Conjunto de normas para conduzir análises de ciclo de vida de produtos e serviços); ISO 14041 (Avaliação do ciclo de vida – Definição de escopo e análise do inventário); ISO 14042 (Avaliação do ciclo de vida – Avaliação do impacto do ciclo de vida); ISO 14043 (Avaliação do ciclo de vida – Interpretação do ciclo de vida); ISO 14045 (Requisitos para análises de ecoeficiência); ISO 14051 (Norma para MFCA – Contabilidade de custo dos fluxos de materiais); ISO 14063 (Comunicação ambiental por partes das empresas); ISO 14064 (Contabilização e verificação de emissões de gases de efeito estufa para suportar projetos de redução de emissões); ISO 14065 (Complementa a ISO 14064 especificando os requisitos para certificar ou reconhecer instituições que farão validação ou verificação da norma ISO 14064 ou outras especificações importantes); ISO 14066 (Requisitos para as empresas que farão a validação e a verificação de

- emissões de gases de efeito estufa – GEE); ISO 14067 (Norma para pegada de carbono em produtos, tratando de requisitos para contabilização e comunicação de emissões de gases de efeito estufa associados a produtos) e ISO 14069 (Guia para as empresas calcularem a pegada de carbono em seus produtos, serviços e cadeia de fornecimento);
- NBR ISO 31000 (Gestão de riscos – Princípios e diretrizes): Esta norma descreve o processo sistemático de gerenciamento do risco, identificando-o, analisando-o e, em seguida, avaliando se o risco deve ser modificado pelo tratamento do risco, a fim de atender a seus critérios de risco. Ao longo de todo este processo, elas comunicam e consultam as partes interessadas e monitoram e analisam criticamente o risco e os controles que o modificam;
 - ISO 45001: 2018: Sistemas de gestão de saúde e segurança ocupacional (substitui a norma britânica OHSAS 18001:2007 – Sistema de gestão de saúde e segurança ocupacional) e é, também, norma de aplicação geral que pode ser certificada por qualquer organização, independentemente de seu porte e ramo de atuação;
 - SMS (Singapura, 2002) & Cool Program (Singapura, 2003): Também normas direcionadas à segurança e saúde do trabalhador;
 - ISO 20000-1: A norma possibilita às empresas auditar práticas até então conduzidas sobre a ótica das melhores práticas propostas pelo Information Technology Infrastructure Library – ITIL. Isto é especialmente vantajoso por permitir que um padrão seja mantido e melhorado através da contribuição de auditores externos e independentes, normalmente, especialistas na área de TI e com ótima formação e experiência profissional;
 - ISO 27001: Evolução da BS 7799, surgida em um grupo de trabalho da indústria e em 1993 tornou-se a Norma Britânica. Sua metodologia foi estruturada para a adoção das melhores práticas na segurança da informação. Os requisitos estabelecidos na norma são genéricos e pretende-se que sejam aplicáveis a qualquer organização. O objetivo básico da norma é ajudar a estabelecer e manter um sistema de gestão da segurança da informação buscando a melhoria contínua;
 - BS 7799-1 (1995), BS 7799-1/2 (1999), ISO 17799-1 (2000), CMM (US, 2000) & CMMI (US, 2002): Outras normas e certificações relacionadas à área de TI: qualidade, capacidade e gerenciamento de informações/risco;

- GoodPriv@cy: Padrão estabelecido internacionalmente que abrange requisitos para o gerenciamento da proteção e privacidade dos dados nas organizações. A certificação GoodPriv@cy atesta que a organização certificada mantém em funcionamento um sistema de gerenciamento para a proteção dos dados, atende aos requisitos estatutários e melhora de forma contínua o gerenciamento da proteção e privacidade dos dados;
- SASSMAQ: O objetivo do Sistema de Avaliação de Segurança, Saúde, Meio Ambiente e Qualidade – SASSMAQ é o de reduzir, de forma contínua e progressiva, os riscos de acidentes nas operações de transporte e distribuição de produtos químicos. O sistema, lançado pela Abiquim em maio de 2001, foi dirigido inicialmente ao modal rodoviário de transporte de cargas;
- APPCC (HACCP): Esta certificação atesta que a empresa possui um Sistema de Gestão certificado em conformidade com a gestão da análise de perigos e pontos críticos de controle – segurança de alimentos;
- BRC (UK, 1998), SQF 20000 (Suíça) & ISO 22000:2005: Boas práticas de higiene e segurança alimentar, conforme acordos e regulamentação específica;
- Transqualit (Green, Aéreo, Farma, Frigo): Esta certificação atesta que a empresa possui um sistema de gestão certificado em conformidade com as especificações correlatas na gestão para transportes;
- NBR 15100 (equivalente à Norma AS/EN 9100:2016): tem a finalidade padronizar, na maior extensão possível, os requisitos para um sistema de gestão de qualidade para a indústria aeroespacial. Além dos requisitos listados na ISO 9001, foram incluídos requisitos específicos do setor aeroespacial, necessários para assegurar a segurança, confiabilidade e qualidade dos produtos aeroespaciais;
- NBR16001: estabelece os requisitos mínimos relativos a um sistema da gestão da responsabilidade social, permitindo à organização formular e implementar uma política e objetivos que levem em conta os requisitos legais e outros, seus compromissos éticos e sua preocupação com a: promoção da cidadania; promoção do desenvolvimento sustentável; e transparência das suas atividades;
- NBR 15401: Sistemas de gestão da sustentabilidade para meios de hospedagem. Esta certificação atesta que a organização que disponibiliza “meios de hospedagem” tem uma atitude de sustentabilidade

correta, controlando seus impactos ambientais e prevenindo a geração de poluição. Com ela, a empresa evita taxações, permitindo à organização formular uma política e objetivos que levem em conta os requisitos legais e as informações referentes aos impactos ambientais, socioculturais e econômicos significativos;

- SA 8000: O padrão SA 8000 (Social Accountability 8000) é baseado nos princípios internacionais contidos na norma Organização Internacional do Trabalho (ILO), UN – Declaração Universal dos Direitos Humanos e a Convenção dos Direitos da Criança. Seu foco é melhorar as condições de trabalho no mundo. Esta intenção pioneira tem levado as organizações a melhorar e demonstrar sua Responsabilidade Social Corporativa (CRS) em relação aos direitos básicos;
- NBR ISO 10001: Gestão da qualidade – satisfação do cliente – diretrizes para códigos de conduta para organizações;
- NBR ISO 10002: Gestão da qualidade – satisfação do cliente – diretrizes para o tratamento de reclamações nas organizações;
- NBR ISO 10003: Gestão da qualidade – satisfação do cliente – diretrizes para a resolução externa de litígios das organizações;
- NBR ISO 10004: Gestão da qualidade – satisfação do cliente – diretrizes para monitoramento e medição;
- NBR ISO 10005: Sistemas de gestão da qualidade – diretrizes para planos da qualidade;
- NBR ISO 10006: Sistemas de gestão da qualidade – diretrizes para a gestão da qualidade em empreendimentos;
- NBR ISO 10007: Sistemas de gestão da qualidade – diretrizes para gestão de configuração;
- NBR ISO 10008: Gestão da qualidade – satisfação do cliente – diretrizes para transações de comércio eletrônico de negócio a consumidor;
- NBR ISO 10012: Sistemas de gestão de medição – requisitos para os processos de medição e equipamentos de medição;
- ISO/TR 10013: Diretrizes para a documentação de sistema de gestão da qualidade;
- NBR ISO 10014: Gestão da qualidade – diretrizes para a percepção de benefícios financeiros e econômicos;
- NBR ISO 10015: Gestão da qualidade – diretrizes para treinamento;

- ISO/TR 10017: Guia sobre técnicas estatísticas para a ABNT NBR ISO 9001:2000;
- NBR ISO 10018: Gestão de qualidade – diretrizes para envolvimento das pessoas e suas competências;
- NBR ISO 10019: Diretrizes para a seleção de consultores de sistemas de gestão da qualidade e uso de seus serviços;
- NBR ISO 19011: Diretrizes para auditoria de sistemas de gestão;
- ISO 10006:2003: Esta norma define como os princípios e práticas de gestão da qualidade relacionam-se com o gerenciamento de projetos. É um documento de diretrizes que não deve ser usado com objetivos de certificação, e sim de padronização. É aplicável a projetos de complexidades variadas, pequenos ou grandes, de curta ou longa duração, em diferentes ambientes e independentemente do tipo de produto ou processo envolvido;
- ISO 21500:2012: Orientações sobre gerenciamento de projeto. Esta norma fornece diretrizes para gerenciamento de projetos e pode ser usada por qualquer tipo de organização, incluindo pública, privada ou organizações comunitárias, e para qualquer tipo de projeto, independentemente de complexidade, tamanho ou duração;
- ISO 13485:2016: Sistema de gestão para qualidade de dispositivos médicos: norma derivada da ISO 9001:2015, é mais prescritiva e serve como conformidade regulatória. Aplicada na indústria de fabricação de dispositivos médico-hospitalares;
- FSC — Manejo florestal: apresenta três tipos de certificado: manejo florestal, cadeia de custódia e madeira controlada. Identifica produtos originados do bom manejo florestal.

Na caminhada pela qualidade e melhoria contínua, a normalização é um elemento relevante. No entanto, tem um viés de adequação somente: as empresas que buscam uma posição diferenciada precisam trabalhar, então, com modelos mais abrangentes e desafiadores: os modelos de excelência.

Prêmio Nacional da Qualidade

A Fundação Nacional da Qualidade (FNQ) realiza, anualmente, o ciclo de avaliação do Prêmio Nacional da Qualidade (PNQ), que reconhece

as organizações que praticam a excelência em gestão no Brasil. A história dos modelos de excelência se inicia com a atuação de Deming no Japão: conforme relatado pela JUSE (2015).

Quando Deming proferiu seu seminário sobre controle de qualidade em 1950, a transcrição do curso de oito dias foi compilada a partir de registros estenográficos, tendo sido cobrada uma taxa aos interessados, mas Deming doou seus royalties para a JUSE. Em reconhecimento à generosidade, o diretor administrativo da instituição propôs usar o valor recebido para financiar um prêmio para comemorar a contribuição e amizade de Deming de forma duradoura e promover o desenvolvimento contínuo do controle de qualidade no Japão, o que foi aprovado por unanimidade pelo conselho de administração da JUSE. Surgiu assim o Prêmio Deming, concedido às organizações que desenvolvem métodos eficazes de gestão da qualidade, estabelecem as estruturas para implementação e colocam os métodos em prática.

A exemplo do Prêmio Deming, surgiu em 1987 o Malcolm Baldrige National Quality Award (Prêmio Nacional da Qualidade Malcolm Baldrige) nos Estados Unidos, concebido para sensibilizar para a gestão da qualidade e reconhecer as empresas dos EUA que implementaram sistemas de gestão da qualidade bem-sucedidos (ASQ, 2018).

Seguiram-se, então, prêmios semelhantes em diversas partes do mundo, como o European Quality Award, Canada Awards for Excellence, etc. Criado em 1991, quando foi fundada a Fundação para o Prêmio Nacional da Qualidade – FPNQ, o Prêmio Nacional da Qualidade é uma grade de excelência que incorpora inúmeras experiências de outros prêmios, servindo de base para a implantação de uma gestão integrada voltada para excelência. A empresa vencedora do primeiro PNQ foi a IBM – Unidade de Sumaré, em 1982.

Desde então, os critérios de avaliações e o próprio modelo de excelência em gestão (MEG), que fundamenta o prêmio, passaram por inúmeras mudanças, chegando ao modelo atual, estruturado na forma de oito fundamentos, desdobrando-se diretamente em temas que, por sua vez, abrem-se em processos para os quais são indicados o ferramental mais adequado (FNQ, 2016).

Os fundamentos da gestão para excelência são um conjunto de valores e princípios que revelam padrões culturais internalizados nas organizações de classe mundial – expressão utilizada para caracterizar uma organização considerada entre as melhores do mundo em gestão

organizacional. No MEG, os fundamentos são expressos em características tangíveis, mensuráveis quantitativa ou qualitativamente, por meio de processos e seus respectivos resultados (FNQ, 2016):

1. PENSAMENTO SISTÊMICO: compreensão e tratamento das relações de interdependência e seus efeitos entre os diversos componentes que formam a organização, bem como entre estes e o ambiente com o qual interagem.

Temas:

- Alinhamento
- Tomada de decisão

2. COMPROMISSO COM AS PARTES INTERESSADAS: estabelecimento de pactos com as partes interessadas e suas interações com as estratégias e os processos, numa perspectiva de curto e longo prazos.

Temas:

- Requisitos das partes interessadas
- Cliente
- Relacionamento com as partes interessadas
- Fornecedor
- Força de trabalho

3. APRENDIZADO ORGANIZACIONAL E INOVAÇÃO: busca e alcance de novos patamares de competência para a organização e sua força de trabalho, por meio da percepção, reflexão, avaliação e compartilhamento de conhecimentos, promovendo um ambiente favorável à criatividade, experimentação e implementação de novas ideias capazes de gerar ganhos sustentáveis para as partes interessadas.

Temas:

- Aperfeiçoamento
- Conhecimento
- Competências essenciais
- Inovação

4. ADAPTABILIDADE: flexibilidade e capacidade de mudança em tempo hábil, frente a novas demandas das partes interessadas e alterações no contexto.

Temas:

- Capacidade de mudar
- Flexibilidade

5. LIDERANÇA TRANSFORMADORA: atuação dos líderes de forma ética, inspiradora, exemplar e comprometida com a excelência, compreendendo os cenários e tendências prováveis do ambiente e dos possíveis efeitos sobre a organização e suas partes interessadas, no curto e longo prazos; mobilizando as pessoas em torno de valores, princípios e objetivos da organização; explorando as potencialidades das culturas presentes; preparando líderes e pessoas; e interagindo com as partes interessadas.

Temas:

- Valores e princípios organizacionais
- Governança
- Cultural organizacional
- Olhar para o futuro
- Sucessão

6. DESENVOLVIMENTO SUSTENTÁVEL: compromisso da organização em responder pelos impactos de suas decisões e atividades, na sociedade e no meio ambiente, e de contribuir para a melhoria das condições de vida, tanto atuais quanto para as gerações futuras, por meio de um comportamento ético e transparente.

Temas:

- Econômico-financeiro
- Ambiental
- Social

7. **ORIENTAÇÃO POR PROCESSOS:** reconhecimento de que a organização é um conjunto de processos, que precisam ser entendidos de ponta a ponta e considerados na definição das estruturas: organizacional, de trabalho e de gestão. Os processos devem ser gerenciados visando à busca da eficiência e da eficácia nas atividades, de forma a agregar valor para a organização e as partes interessadas.

Temas:

- Informações organizacionais
- Gestão por processos
- Produto

8. **GERAÇÃO DE VALOR:** alcance de resultados econômicos, sociais e ambientais, bem como de resultados dos processos que os potencializam, em níveis de excelência e que atendam às necessidades e expectativas das partes interessadas.

Tema:

- Resultados sustentáveis

Os oito fundamentos, que são mostrados no diagrama do MEG, na **Figura 1.7**, são desdobrados em temas, servindo de base para a avaliação e pontuação das empresas no prêmio.

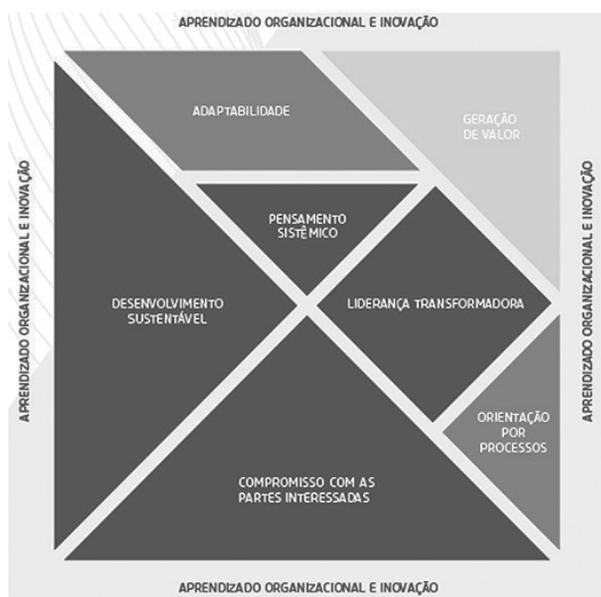


Figura 1.7: Diagrama do MEG. A figura simboliza um modelo de relacionamento entre a organização – considerada como um sistema adaptável, gerador de produtos e informações – e seu ambiente organizacional e tecnológico, além do próprio ambiente externo.

Fonte: FNQ (2016)

Atividades

Atendem aos objetivos 1 e 3

1. Para elaboração desta apostila que você lê, diversos profissionais foram envolvidos. Que fundamentos do MEG você identifica como relacionados ao desenvolvimento da apostila e em fazer com que estivesse disponível para você?

2. A empresa XYZ vem enfrentando uma série de dificuldades nos últimos anos: fabricante tradicional de peças mecânicas, ela tem perdido mercado para empresas mais novas e, principalmente, para algumas ligadas a grupos multinacionais. Um fio de esperança surgiu quando ela fechou o contrato de fornecimento para peças de reposição de tratores, em volume considerável. No entanto, um erro no processo produtivo fez com que o primeiro lote fornecido fosse devolvido pelo cliente, devido ao fato de as peças estarem fora das especificações.

O supervisor de produção ficou muito aborrecido com o ocorrido e demitiu o inspetor de qualidade da fábrica. Depois disso, ele mesmo resolveu verificar os lotes que estavam prontos para serem despachados para o cliente e identificou que também apresentavam não conformidades. Ele achou isso muito estranho e começou a investigar o que havia de errado: os lotes eram inspecionados mediante um calibre passa – não passa, usado para verificar se as medidas estavam dentro dos limites máximos e mínimos da especificação do cliente. No entanto, este calibre estava desgastado e, por conta disso, diversos componentes não conformes haviam sido aprovados pelo inspetor.

O fabricante de tratores quer saber o que a empresa XYZ vai fazer para evitar que problemas como esse se repitam, ou seja, quer que a empresa desenvolva um plano de melhoria da qualidade.

Como base neste cenário:

- Em que fase evolutiva do controle da qualidade a empresa XYZ está? Ela deve permanecer nesta situação ou deve traçar um plano para sair dela?
- Indique ao menos três requisitos normativos da ISO 9001:2015 em que a XYZ deveria focar sua atenção no plano de melhoria da qualidade.
- Indique ao menos dois fundamentos do MEG em que a XYZ deveria focar sua atenção para melhorar seu desempenho em termos de qualidade.

Resposta comentada:

1. Ainda que a resposta possa variar conforme a análise feita, para elaboração da citada apostila, podemos identificar como mais pertinentes os seguintes fundamentos:

a) **PENSAMENTO SISTÊMICO:** compreensão e tratamento das relações de interdependência e seus efeitos entre os diversos componentes que formam a organização, bem como entre estes e o ambiente com o qual interagem – devido ao processo envolver diferentes atividades, como desenvolvimento e avaliação de conteúdo, revisão, edição, disponibilização, etc.

b) **COMPROMISSO COM AS PARTES INTERESSADAS:** estabelecimento de pactos com as partes interessadas e suas interrelações com as estratégias e processos, numa perspectiva de curto e longo prazos – por envolver diversas pessoas: elaboradores, revisores, designers, bem como professores, tutores e os próprios alunos.

c) **ORIENTAÇÃO POR PROCESSOS:** reconhecimento de que a organização é um conjunto de processos, que precisam ser entendidos de ponta a ponta e considerados na definição das estruturas: organizacional, de trabalho e de gestão. Os processos devem ser gerenciados visando à busca da eficiência e da eficácia nas atividades, de forma a agregar valor para a organização e as partes interessadas – pelas mesmas razões apontadas acima.

2. A XYZ ainda está na fase da inspeção, ou seja, os primórdios do controle da qualidade. Isso não é adequado para o momento atual e a justificativa está evidenciada no que aconteceu: a inspeção tardia e falha

permitiu que grande quantidade de componentes de qualidade inaceitável fosse produzida, causando forte desgaste com o cliente e causando um prejuízo considerável.

A fabricação de peças mecânicas envolve processos que geram peças com variações dimensionais e tais variações devem ser acompanhadas para garantir que o processo esteja sob controle. Desta forma, o ideal é que a XYZ implemente de imediato o CEQ. No entanto, é conveniente que ela busque mais adiante estratégias mais robustas de controle de qualidade: uma clara justificativa para isso foi o fato de o inspetor ter sido demitido. O problema foi sistêmico, devido a um sistema de qualidade bastante frágil e, desta forma, a culpa não foi exclusiva do inspetor.

Assim, seria adequado que práticas de desenvolvimento do pessoal, treinamento, busca pela melhoria contínua por meio da implementação do TQC/TQM estivessem nos planos da XYZ. Neste sentido, o uso da ISO 9001:2015 seria uma boa forma de estruturar as mudanças. Alguns dos requisitos da ISO 9001:2015 em que a XYZ deveria ter foco são critérios como: 5.1. Liderança e comprometimento; 5.3. Papéis, responsabilidades e autoridades organizacionais; 6.3. Planejamento de mudanças; 7.1.4. Ambiente para operação dos processos; 7.1.5. Recursos de monitoramento e medição; 7.3. Conscientização; 8.1. Planejamento e controle operacionais; 8.2. Requisitos para produtos e serviços; 8.2.1. Comunicação com o cliente, 8.6. Liberação de produtos e serviços; 8.7. Controle de saídas não conformes; 9.1. Monitoramento, medição, análise e avaliação; 9.1.2. Satisfação do cliente; 9.1.3. Análise e avaliação; 10.2. Não conformidade e ação corretiva e 10.3. Melhoria contínua.

E, quanto ao MEG do PNQ, os fundamentos 2. COMPROMISSO COM AS PARTES INTERESSADAS (estabelecimento de pactos com as partes interessadas e suas interrelações com as estratégias e processos, numa perspectiva de curto e longo prazos); 3. APRENDIZADO ORGANIZACIONAL E INOVAÇÃO (busca e alcance de novos patamares de competência para a organização e sua força de trabalho, por meio da percepção, reflexão, avaliação e compartilhamento de conhecimentos, promovendo um ambiente favorável à criatividade, experimentação e implementação de novas ideias capazes de gerar ganhos sustentáveis para as partes interessadas); 5. LIDERANÇA TRANSFORMADORA (atuação dos líderes de forma ética, inspiradora, exemplar e comprometida com a excelência, compreendendo os cenários e tendências prováveis do ambiente e dos possíveis efeitos sobre a organização e suas partes interessadas, no curto e longo prazos; mobilizando as pessoas

em torno de valores, princípios e objetivos da organização; explorando as potencialidades das culturas presentes; preparando líderes e pessoas; e interagindo com as partes interessadas) e 7. ORIENTAÇÃO POR PROCESSOS (reconhecimento de que a organização é um conjunto de processos, que precisam ser entendidos de ponta a ponta e considerados na definição das estruturas: organizacional, de trabalho e de gestão. Os processos devem ser gerenciados visando à busca da eficiência e da eficácia nas atividades, de forma a agregar valor para a organização e as partes interessadas) parecem ser os mais urgentes para a XYZ reverter a situação em que se encontra.

Conclusão

Ainda que a qualidade seja algo implícito aos produtos, serviços e processos, dependendo da percepção e aceitação das pessoas, as empresas precisam identificar o que deve ser feito para que os clientes tenham a percepção favorável quanto à qualidade do que lhes é oferecido.

Sem tal percepção, os consumidores desistem da compra ou buscarão outras fontes e isso faria com que as empresas de “baixa qualidade” ficassem sem receita suficiente para se manterem. Desta forma, a qualidade é uma questão de sobrevivência para as empresas e, conseqüentemente, a empresa deve utilizar estratégias, ferramentas, normas e modelos que permitam alcançar níveis adequados de qualidade e esforçar-se para superar constantemente tais patamares, em processos de melhoria contínua.

Resumo

O controle da qualidade evoluiu (e continua evoluindo) ao longo do tempo: do trabalho artesanal executado para uso próprio, passou pela fase em que os mestres ensinavam aos aprendizes, ao que se seguiu o aumento dos volumes produzidos na época da Revolução Industrial, com a separação das atividades de produção e inspeção.

Ao longo do século XX, a utilização das técnicas de amostragem no controle estatístico da qualidade (CEQ) trouxe uma realidade distinta, servindo de base para que estratégias relacionadas ao envolvimento de

todos, treinamento e a busca pela melhoria contínua fossem posteriormente incorporadas ao dia a dia das empresas, no que foi denominado o controle da qualidade total (TQC). A ascensão da qualidade ao nível estratégico da gestão das empresas, bem como a ampliação do TQC em termos de abrangência completou esse ciclo, com a gestão da qualidade total (TQM).

Tal evolução exigiu que normas específicas de qualidade, bem como meio ambiente, segurança, saúde ocupacional, responsabilidade social e outras fossem desenvolvidas e utilizadas por diversos grupos e organizações. Mas isso não era suficiente para diferenciar o desempenho das empresas. Surgem, então, os modelos de excelência em gestão, que no Brasil é caracterizado pelo Prêmio Nacional da Qualidade (PNQ), da Fundação Nacional da Qualidade (FNQ).

Leituras recomendadas

NORMAS. British Standards Institution. São Paulo, 2018. Disponível em: <https://www.bsigroup.com/pt-BR/Normas/>. Acesso em: 20 mar. 2018.

PERGUNTAS e respostas: saiba mais sobre a ABNT e as normas técnicas. Associação Brasileira de Normas Técnicas – ABNT. Rio de Janeiro, [20--?]. Disponível em: <http://www.abnt.org.br/paginampe/perguntas-e-respostas>. Acesso em: 28 mar. 2018.

Informações sobre o próximo conteúdo (opcional)

Na próxima aula, iniciaremos os estudos dos *métodos estatísticos para o controle e melhoria da qualidade*. Veremos o que são e como ocorrem as variações nos processos, bem como o ciclo PDCA de melhoria contínua.

Referências

AMERICAN SOCIETY FOR QUALITY – ASQ. What is the Malcolm Baldrige National Quality Award (MBNQA)?, ASQ, 2018. Disponível em: <http://asq.org/learn-about-quality/malcolm-baldrige-award/overview/overview.html>. Acesso em: 29 maio 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. *ABNT NBR ISO 9001: sistemas de gestão da qualidade: requisitos*. Rio de Janeiro: ABNT, 2015.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. Normalização. Definição. *ABNT*, 2014. Disponível em: <http://www.abnt.org.br/normalizacao/o-que-e/o-que-e>. Acesso em: 26 maio 2018.

CAMPOS, V. F. *TQC: controle da qualidade total (no estilo japonês)*. São Paulo: INDG, 2004.

CORREA, H. L. *Teoria geral da administração: abordagem histórica da gestão de produção e operações*. São Paulo: Atlas, 2003.

COSTA, A. F. B.; EPPRECHT, E. K.; CARPINETTI, L. C. R. *Controle estatístico de qualidade*. São Paulo: Atlas, 2004.

CROSBY, P. *Quality is Free*. New York: McGraw-Hill, 1979.

DEMING, W. E. *Out of the Crisis*. 2. ed. Massachusetts: Mit Press, 2000.

DUARTE, E. E. *Tecnologia militar e desenvolvimento econômico: uma análise histórica*. Texto para discussão 1748. Rio de Janeiro: Instituto de Pesquisa Econômica Aplicada – IPEA, junho de 2012. Disponível em: http://repositorio.ipea.gov.br/bitstream/11058/1114/1/TD_1748.pdf. Acesso em: 19 dez. 2018.

FEIGENBAUM, A. V. *Controle da qualidade total*. São Paulo: Makron Books, 1994.

FOREST STEWARDSHIP COUNCIL – FSC. Certificação. *Florestas para Todos – FSC Brasil*. São Paulo, [201-?]. Disponível em: <https://br.fsc.org/pt-br/certificacao>. Acesso em: 26 mar. 2018.

FUNDAÇÃO NACIONAL DA QUALIDADE – FNQ. *Novo modelo de excelência da gestão – MEG*. São Paulo: FNQ, 2016.

FUNDAÇÃO VANZOLINI. Certificação. Normas de sistemas de gestão. *Portal Vanzolini*, 2015. Disponível em: <http://vanzolini.org.br/certificacao/normas-de-sistema-de-gestao/>. Acesso em: 26 maio 2018.

GARVIN, D.A. What Does “Product Quality” Really Mean? *MIT Sloan Management Review*: Outono 1984, October 15, 1984. Disponível em: <https://sloanreview.mit.edu/article/what-does-product-quality-really-mean/>. Acesso em: 16 maio 2018.

GARVIN, D. A. *Gerenciando a qualidade*. 3. ed. Rio de Janeiro: QualityMark, 2002.

GEHLEN, R. Z. C. Referências normativas da auditoria e normas ISO. In: MATTOS, J. G.; GEHLEN, R. Z. C. *Certificação*. Porto Alegre: SAGAH, 2018a, p. 51-62.

GEHLEN, R. Z. C. Termos e definições. In: MATTOS, J. G.; GEHLEN, R. Z. C. *Certificação*. Porto Alegre: SAGAH, 2018b, p. 63-76.

GONÇALVES, C. F. F. *Ergonomia e qualidade do serviço bancário: uma metodologia de avaliação*. Tese (Doutorado em Engenharia de Produção). Florianópolis: Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, 1995.

INSTITUTO NACIONAL DE METROLOGIA QUALIDADE E TECNOLOGIA – INMETRO. Sinmetro – Sistema Nacional de Metrologia, Normalização e Qualidade Industrial. Brasília: INMETRO, 2012. Disponível em: <http://www.inmetro.gov.br/inmetro/sinmetro.asp#4>. Acesso em: 2 abr. 2018.

JONES, G. R.; GEORGE, J. M. *Administração contemporânea*. 4. ed. Porto Alegre: AMGH, 2011.

JURAN, J. K. *Quality Control Handbook*. New York: John Willey & Sons, 1991.

Union of Japanese Scientists and Engineers – JUSE. *Union of Japanese Scientists and Engineers – JUSE*, 2015. Disponível em: <http://www.juse.or.jp/english/>. Acesso em: 24 maio 2018.

MACHADO JR., J. A.; ROTONDARO, R. G. Mensuração da qualidade de serviços: um estudo de caso na indústria de serviços bancários. *Gest. Prod.*, 2003, vol. 10, n. 2, p. 217-230.

OLIVEIRA, S. T. *Ferramentas para o aprimoramento da qualidade*. São Paulo: Pioneira, 1995.

PALADINI E. P. *Qualidade total na prática*. Implantação e avaliação de sistemas de qualidade total. São Paulo: Atlas, 1994.

PARANTHAMAN, D. *Controle da qualidade*. São Paulo: McGraw-Hill, 1990.

PETERS, T.; WATERMAN, R. *Vencendo a crise*. São Paulo: Harper Row, 1982.

RAMOS, E. M. L. S.; ALMEIDA, S. S.; ARAÚJO, A. R. *Controle estatístico da qualidade*. Porto Alegre: Bookman, 2013.

ROCHA, H. M. *Gestão pela qualidade*. Rio de Janeiro: FGV Management, 2010, 62 p.

ROCHA, H. M. Estudo de micromovimentos. In: KLIPPEL, A. F. et al. (org.). *Engenharia de métodos*. 2. ed. Porto Alegre: SAGAH, 2017, p. 101-111.

ROSSATO, I. F. *Uma metodologia para a análise e solução de problemas*. Dissertação (Mestrado Engenharia de Produção). Florianópolis: Universidade Federal de Santa Catarina, 1996.

SALVIATO, S. *Uma metodologia de solução de problemas com enfoque na aprendizagem organizacional: um estudo de caso aplicado no BESC*. Dissertação (Mestrado Engenharia de Produção). Florianópolis: Universidade Federal de Santa Catarina, 1999.

SANTOS, J. A. N. *Engenharia de métodos*. Apostila. Rio de Janeiro: Universidade do Estado do Rio de Janeiro, 2008.

XANTHOPOYLOS, S. P. *Produtos e serviços*. FGV Management (apostila). Rio de Janeiro: FGV, 2009.

Aula 2

Métodos estatísticos para o controle
e melhoria da qualidade

Metas

Apresentar a introdução da estatística no controle para melhoria da qualidade, reduzindo as variações no processo. Destacar, principalmente, o ciclo PDCA, que representa uma importante ferramenta nesta área.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. saber o porquê do uso da estatística no processo da qualidade;
2. conhecer o ciclo PDCA e sua utilidade no setor da qualidade de produtos e serviços.

Pré-requisitos

Funções estatísticas e distribuição normal, conteúdos abordados nas disciplinas Estatística I e II, que são pré-requisitos para a presente disciplina.

Introdução

Não existe peça, objeto ou máquina que seja idêntico a outro: pequenas diferenças – na maioria das vezes, imperceptíveis – sempre existirão. Da mesma forma, um trabalho executado nunca será idêntico a outro: podem ocorrer, por exemplo, diferenças na velocidade, posição, etc.

Tais variações são normais e, se mantidas dentro de limites estreitos, não costumam causar problemas. No entanto, quando excessivas, fora de faixas aceitáveis, podem causar problemas de desempenho, o que não é desejável.

Desta forma, é necessário utilizar um método estruturado para garantir que tudo o que fazemos esteja dentro do esperado. Também é importante que haja um método definido para nos conduzir às melhorias de desempenho.

É isso que você estudará nesta aula, começando pela discussão sobre as variações nos processos e nos produtos, abordando em seguida o ciclo de melhoria contínua PDCA (Plan-Do-Check-Act), utilizado pelas organizações que buscam a excelência em seus processos de qualidade. Bons estudos!

O controle estatístico da qualidade só existe porque temos diferenças entre peças, componentes de um lote, entre lotes de produtos, entre processos, etc. Se tais diferenças não existissem, isto é, se “tudo fosse igual”, não precisaríamos nos preocupar com a *qualidade* e, menos ainda, em fazer um *controle estatístico* dela.

Mas isso parece estranho! Afinal, se observarmos um conjunto de parafusos do mesmo tipo, eles nos parecem idênticos! Como, então, afirmar que há diferenças entre eles?

Bem, como certeza, você conhece irmãos gêmeos e, já deve ter ouvido alguém dizer que eles são “idênticos”, não é mesmo? Mas isso é verdade? São mesmo “idênticos”?



Figura 2.1: Gêmeas: muito parecidas, mas, elas são, de fato, “idênticas”? Ou há diferenças bem pequenas entre elas? Algo que exige muita atenção para conseguirmos identificar e perceber?

Fonte: <https://pixabay.com/pt/retrato-mulher-felicidade-pessoas-3064773/>

A resposta a essa pergunta é: não são idênticos(as). Há diferenças mínimas entre eles(as), as quais são difíceis de serem percebidas: precisamos olhas com muita atenção, fazer comparações, analisar minuciosamente os detalhes até que consigamos perceber tais diferenças. É algo tão difícil quanto percebermos as diferenças entre tomates de um mesmo lote.



Figura 2.2: Tomates: também muito parecidos. Mas seria correto dizermos que são iguais? Se fossem, as donas de casa não os selecionariam quando fazem as compras: bastaria pegarem qualquer um, já que todos seriam “iguais”.

Fonte: <https://pt.freeimages.com/photo/tomatoes-1323819>

Nesse momento, você pode estar questionando: ok, gêmeos, frutas, legumes, etc. podem ser muito parecidos e não serem iguais. Mas, no caso dos parafusos, isso não faz sentido, pois eles são produzidos em grande escala, usando exatamente o mesmo material e os mesmos processos. Assim, não há diferença entre eles!

Bem, isso não é verdade: a matéria-prima utilizada para produzir os parafusos não é 100% homogênea e isso faz com que, durante o processo produtivo, surjam pequenas variações dimensionais, devido a diferenças de dureza e de elasticidade do material. Além disso, alterações na temperatura onde o processo ocorre fazem com que haja mais ou menos dilatação do material, igualmente acarretando em variações dimensionais.

Vibração, velocidade de operação e outros fatores nas máquinas utilizadas são, também, causas de variações de forma e dimensões nos parafusos. Da mesma forma, tratamentos superficiais posteriores (utilizados para proteger a superfície do parafuso contra oxidação, por exemplo) também ocorrem por meios de banhos químicos, que não são totalmente homogêneos, devido a haver diferenças nas temperaturas em pontos distintos, o que faz com que surjam alterações na coloração e na espessura da camada de proteção.



Figura 2.3: Parafusos: parecem todos iguais, não é mesmo? Mas, será que são mesmo? Ou será que há diferenças quase imperceptíveis entre eles, seja na cor, nas formas ou dimensões? Para podermos responder a tal pergunta, precisamos olhar com atenção e, provavelmente, recorrer a instrumentos de medida de grande precisão.

Fonte: <https://pixabay.com/pt/parafuso-parafusos-de-madeira-spax-1711596/>

Tendo em vista o exposto, o segredo para identificar tais diferenças é similar ao que utilizamos para diferenciar gêmeos e tomates: a análise minuciosa, detalhada, podendo, na maioria das vezes, recorrer a instrumentos como paquímetros, micrômetros, etc.

Ou seja, é importante compreender que as variações ocorrem em qualquer processo e que, por conta delas, há a necessidade do controle estatístico dos processos. Com eles, podemos identificar quando tais variações ultrapassam o que poderia ser considerado “normal”, isto é, quando há um problema ao invés de meras variações **randômicas** inerentes ao processo.

E o controle prevê que, caso detectadas anomalias, devem ser tomadas providências para identificar as causas-raiz e estabelecidas medidas de contenção e implementação de ações que evitem a ocorrência de novas anomalias. Para tanto, deve ser utilizado um método estruturado para melhoria da qualidade.

Randômicas

Derivada de randômico, cujo significado está relacionado a algo que é aleatório, não previsível, que varia sem uma regra ou padrão claro ou previamente definido.

Variações no processo

Antes de discutirmos as variações que ocorrem nos processos, vamos conceituar *processos* e compreender suas implicações nos produtos e serviços. De acordo com Rocha (2017), é preciso compreender a diferença entre *métodos* e *processos*: o primeiro é uma forma de organizar os passos ou procedimentos, de forma a atingir objetivos e metas. Desta forma, a melhoria dos *métodos* está relacionada a melhorar a produtividade do trabalho, por meio da simplificação e redução de tempos e custos, pela introdução de melhorias em ferramentas, máquinas e equipamentos, ou habilidades e competências do pessoal envolvido. Assim, um método de trabalho “está relacionado à forma como o trabalho é executado, ou seja, como o processo produtivo foi planejado” (ABBUD, 2017, p.33), visto que um processo produtivo engloba diferentes métodos de trabalho.

O conceito de *processo*, por sua vez, está relacionado a algum tipo de transformação. Assim, o processo de preparação de um bolo envolve transformar os ingredientes (que são as entradas do processo) em saídas (nesse exemplo, uma saída única, que é o bolo pronto). Para que tal transformação aconteça, são necessárias ferramentas (ex: batedeira, espátula, forma, forno, etc.) e técnicas (no caso, a própria receita). Já o processo de preenchimento de um documento transforma um documento em branco em um documento preenchido, utilizando uma caneta (ou computador,

caso seja um documento eletrônico), tendo a capacidade de interpretação e conhecimentos necessários para o preenchimento dos diversos campos como as técnicas utilizadas.

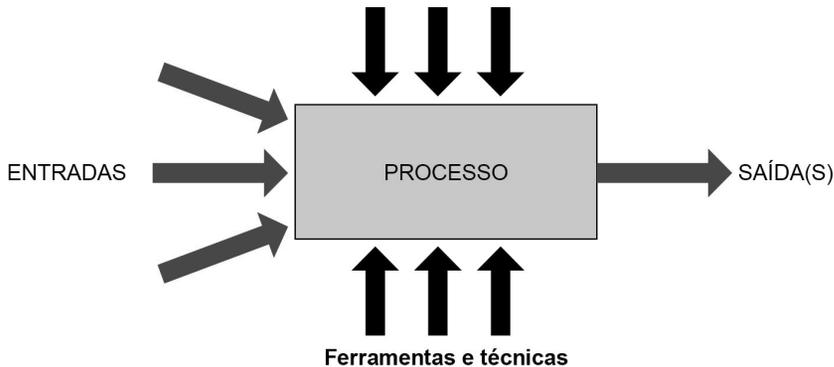


Figura 2.4: Processo, suas entradas, ferramentas, técnicas e saídas: o executor do processo utiliza ferramentas e técnicas para transformar as entradas do processo em saída(s). Se não houver transformação, não é um processo.

Fonte: Adaptado de PMI (2013).

Importante destacar que os processos não existem isoladamente: eles se encadeiam de tal forma que as saídas de um processo são entradas de processos subsequentes. Por exemplo, o bolo pronto (saída do processo de preparação de um bolo) é entrada para o processo de comê-lo (ou vendê-lo, etc.). Da mesma forma, o processo de preencher um documento só foi possível porque, antes dele, houve um processo para elaborá-lo e outro para disponibilizá-lo para preenchimento.

Esse encadeamento de processos nas empresas é ainda mais abrangente do que nestes exemplos: há os processos de desenvolvimento de produtos, os processos de produção, de distribuição, etc. Tal encadeamento de processos mostra a importância de seu adequado gerenciamento, pois a falha de um processo pode comprometer todos os demais subsequentes. Por exemplo, a falha no desenvolvimento de um novo produto comprometerá sua produção, distribuição e comercialização.

Mundim et al. (2002) destaca que uma das dificuldades encontradas pelas organizações é justamente o gerenciamento integrado do processo de desenvolvimento de seus produtos, os quais devem ser tecnologicamente atualizados, com características de desempenho, custo e distribuição condizentes com o atual nível de exigência dos consumidores. Mas não é só questão de haver um bom projeto para que surja um produto

adequado e de sucesso: como apontado por Garvin (1984; 2002), dentre as dimensões básicas da qualidade (vide Aula 1), estão não só o desempenho do produto e sua durabilidade, mas também a conformidade (ou, como encontrado algumas vezes na literatura, “conformação”).

Ou seja, o grau em que as peças executadas correspondem ao projeto ou quão bem um produto ou um serviço atendem às especificações de projeto. Por isso, Clark e Fujimoto (1991) defendem que a estratégia de produto de uma empresa e como ela se organiza e gerencia o desenvolvimento, determinarão como o produto se portará no mercado: a maneira como esta realiza o desenvolvimento, sua velocidade, eficiência e qualidade do trabalho irá determinar a competitividade do produto.

As variações inerentes aos diversos processos vão se acumulando e podem, ao final, representar valores inaceitáveis. Vamos compreender como tal acúmulo acontece: suponhamos que precisemos encaixar 10 cubos de 10 mm de lado em um rasgo cujo comprimento seja de 101 mm. A princípio, parece não haver problemas em executar tal operação, visto que há 1 mm de folga. No entanto, variações superiores a 0,1 mm em cada um dos cubos podem tornar isso impossível.

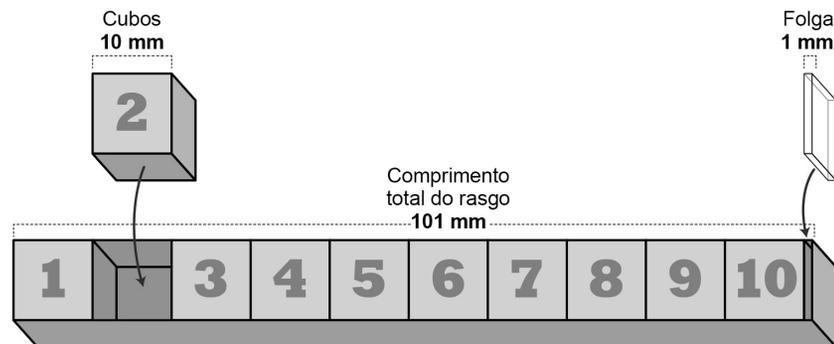


Figura 2.5: Dez cubos de 10 mm montados em um rasgo de 101 mm: repare a existência de uma pequena folga à direita, prevista para permitir a montagem dos cubos na posição. Entretanto, ela não pode ser excessiva, para que os cubos não fiquem “soltos”.

O mesmo acontece no processo de desenvolvimento e a elaboração de produtos: a variabilidade (ou variação, ou ainda, dispersão) está presente em todos os processos de produção de bens e de fornecimento de serviços, mesmo que não sejam facilmente perceptíveis (como nos exemplos discutidos anteriormente, dos gêmeos e das frutas).

Mesmo os produtos não defeituosos apresentam variações dentro dos limites de sua especificação, o que significa dizer que estes produtos não são exatamente idênticos. No processo de fabricação de um bem ou serviço, atuam diversos fatores que afetam suas características de qualidade. Neste sentido, o processo pode ser visualizado como um conjunto de causas de variação. O problema ocorre quando o somatório de tais variabilidades (como no caso dos cubos) leva à inadequação e não conformidade do produto ou serviço. Ou seja, se temos uma faixa de variabilidade aceitável para o conjunto ou produto, as variabilidades dos elementos envolvidos não deveriam ultrapassá-lo.

Por exemplo, a folga de 1 mm entre o rasgo onde os cubos deveriam ser montados e a dimensão ocupada por eles parece ser bastante apropriada: nem excessiva a ponto de os cubos ficarem “soltos”, mas suficiente que eles possam ser montados. Quanto mais nos afastamos do valor nominal de 1 mm de folga, pior a funcionalidade do conjunto, com os cubos ficando cada vez mais “soltos” ou, no outro extremo, tornando cada vez mais difícil seu posicionamento (ao ponto de se tornar impossível a montagem). Podemos caracterizar tal situação como um “produto defeituoso”, no qual as características da qualidade não satisfazem a uma determinada especificação. Ou seja, o defeito é uma não conformidade.

Vamos, porém, imaginar que existissem dois fabricantes, A e B, dos cubos e da base de encaixe, sendo que A produzisse com menos variabilidade que B. Isso faria com que os produtos de A fossem considerados “melhores” (ou, de melhor qualidade) que os de B, não é mesmo? Isso acontece porque a redução da variabilidade dos processos permite a produção de itens cuja característica da qualidade de interesse – isto é, o que é importante para o bom funcionamento e adequado ao uso pelos clientes – esteja próxima a um valor-alvo desejado (no nosso exemplo, 1 mm de folga) e dentro dos limites de especificação estabelecidos. O emprego de ferramentas estatísticas contribui para que a redução da variabilidade possa ser alcançada de forma eficaz.

O ciclo PDCA

Walter Andrew Shewhart (1891-1967), um dos membros do Departamento de Garantia da Qualidade da Bell Telephone Laboratories (vide Aula 1), desenvolveu na década de 1920 um modelo para concretizar

transformações nas empresas, que previa incrementos constantes de melhora da qualidade, envolvendo todos os empregados da empresa, inclusive gestores (WALTON, 1989).

No entanto, tal modelo ganhou notoriedade a partir de 1950, quando William Edwards Deming (1900-1993), outro “guru da qualidade” e membro do mesmo grupo, apresenta o “ciclo de Shewhart” em todos os seminários sobre controle de qualidade para administradores e engenheiros no Japão, para os quais havia sido convidado pela JUSE (Union of Japanese Scientists and Engineers) (vide Aula 1). Por esta razão, o “ciclo de Shewhart” passou a ser conhecido como “ciclo de Deming” (WALTON, 1989).

O modelo, que é mais conhecido como PDCA, a forma abreviada em inglês de planejar (P – *Plan*), executar (D – *Do*), verificar (C – *Check*) e agir (A – *Act*), prevê um processo de melhora contínua (ou *kaizen*), baseado na repetição de um ciclo incremental de qualidade e é aplicável em qualquer processo ou problema (ANDRADE, 2003).



Figura 2.6: Ciclo PDCA. Trata-se de um ciclo de melhoria contínua, cuja sigla vem das iniciais em inglês: *plan* (planejar), *do* (fazer, executar), *check* (verificar) e *act* (agir, atuar).

Fonte: <https://pixabay.com/pt/plano-fazer-sele%C3%A7%C3%A3o-ato-artes-686327/>

A mesma lógica que usamos para planejar uma viagem é aplicada nas empresas e na gestão de negócios. As decisões são tomadas da mesma forma que determinamos quando e como a referida viagem ocorrerá (por exemplo, se de carro, de ônibus ou de avião; de dia ou de noite; com ou sem paradas e baldeações, etc.) e que seguimos os

planos estabelecidos para viajar, fazendo constantes verificações ao longo da viagem (por exemplo, consultar horários, confirmar se entramos no ônibus correto, ou se temos combustível suficiente no carro, etc.) para, com base nessa análise, tomarmos decisões (por exemplo, se pararemos antes do previsto, caso estejamos cansados).

Antes de se iniciar qualquer atividade, é preciso estabelecer as ações a ser executadas e que sequência isto se dará, os recursos necessários para tal (pessoas, máquinas, equipamentos e capital), bem como a calendarização das ações e da necessidade dos recursos envolvidos. Esta é a etapa de planejamento (P) do PDCA. Uma vez estabelecido o plano para alcançar os objetivos estabelecidos (por exemplo, melhorar a qualidade), tais passos são seguidos, isto é, executa-se o que foi planejado, que é a fase D (*do*, em inglês) do PDCA.

Mas, por mais fielmente que os passos planejados sejam executados, isso não é garantia de que os resultados ocorrerão exatamente como planejado, afinal há muitas variáveis envolvidas, as quais causam distúrbios diversos e, conseqüentemente, impactam o andamento das atividades e os resultados. Por exemplo, se o horário previsto para chegada de um ônibus em determinada cidade for 14h, será muito difícil que ele chegue exatamente neste horário: na verdade, é provável que ele chegue alguns minutos antes ou depois. Além disso, engarrafamentos, chuvas fortes, obras, um pneu furado, etc. podem causar atrasos substanciais.

O mesmo acontece nas empresas: variáveis envolvendo as operações ou fornecedores, isto é, fatores internos e externos, falhas eventuais, execução inapropriada, etc., podem causar desvios no andamento das atividades. E aí entra a importância da fase seguinte do PDCA: a verificação (*check*, em inglês): é necessário verificar constantemente o andamento do que está sendo feito, para sabermos se tudo ocorre de acordo com o previsto e aceitável. Falamos, assim, de comparar os resultados da execução com o que foi planejado. Por exemplo, se uma empresa estabelece um plano de vendas, ela precisa controlar esse processo, ou seja, monitorar as vendas, comparando-as constantemente com o plano, de tal forma que os desvios sejam detectados e as ações pertinentes sejam tomadas para reverter qualquer tendência desfavorável, de forma que os objetivos da empresa sejam alcançados.

Pequenas variações são esperadas e aceitáveis (como no caso do ônibus que chega um pouco antes ou um pouco depois das 14h), mas as grandes variações causam problemas (por exemplo, um atraso excessivo do ônibus pode nos levar a perder um compromisso profissional). E isso explica

a importância dada por Deming ao PDCA: sabedor da variabilidade presente em todos os processos de produção de bens e serviços, ele sabia a importância de agir quando os desvios fossem prejudiciais aos resultados da empresa. Essas ações eram previstas na última fase do ciclo: *Act* (agir, em inglês).

O ciclo apresentado por Deming nos seminários é visto a seguir.

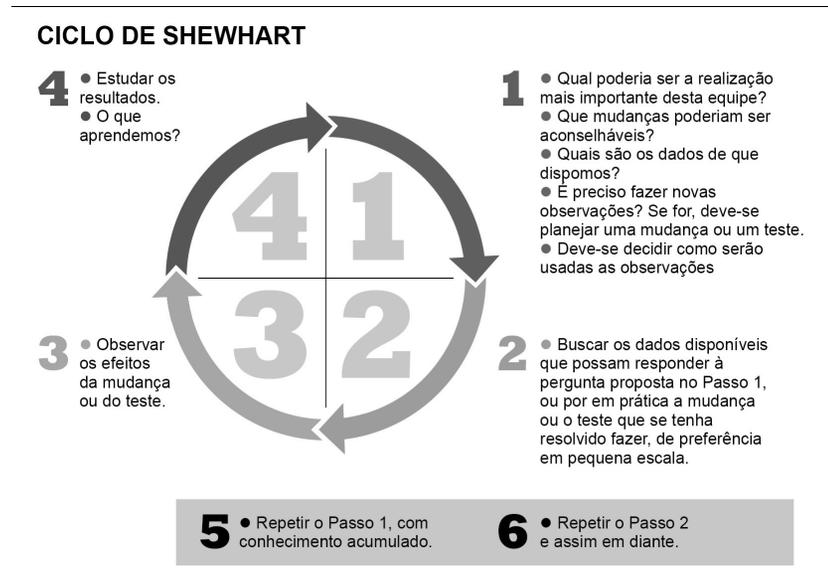


Figura 2.7: Ciclo de Shewhart. Hoje em dia conhecido como PDCA, o ciclo com quatro etapas foi utilizado por Deming nos anos 1950, nos seminários apresentados para administradores e engenheiros no Japão. Por se tratar de um ciclo, ao invés de uma sequência linear, é comumente reconhecido como um ciclo de melhoria contínua.

Fonte: Adaptado de Deming (2000).

Tal conceito foi atualizado, chegando à versão do ciclo PDCA mais comum nos dias de hoje, mas que mantém a essência do que fora desenvolvido por Shewhart.

CICLO DE PDCA

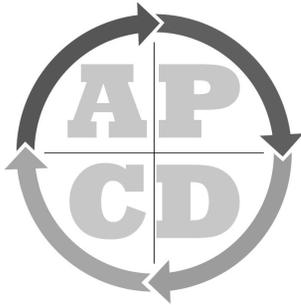


Figura 2.8: Ciclo PDCA. Ainda que oriundo da forma abreviada em inglês de *Plan, Do, Check e Act*, a denominação do ciclo é utilizada desta forma na literatura, mesmo em textos em diversos idiomas (inclusive no Brasil).

Fonte: Adaptado de Campos (2004).

Campos (2004) desdobra a aplicação do PDCA em situações de manutenção (quando o processo é repetitivo) e melhoria (quando há metas específicas) do controle, como mostrado na **Figura 2.9**.

CICLO DE PDCA DE CONTROLE DE PROCESSOS

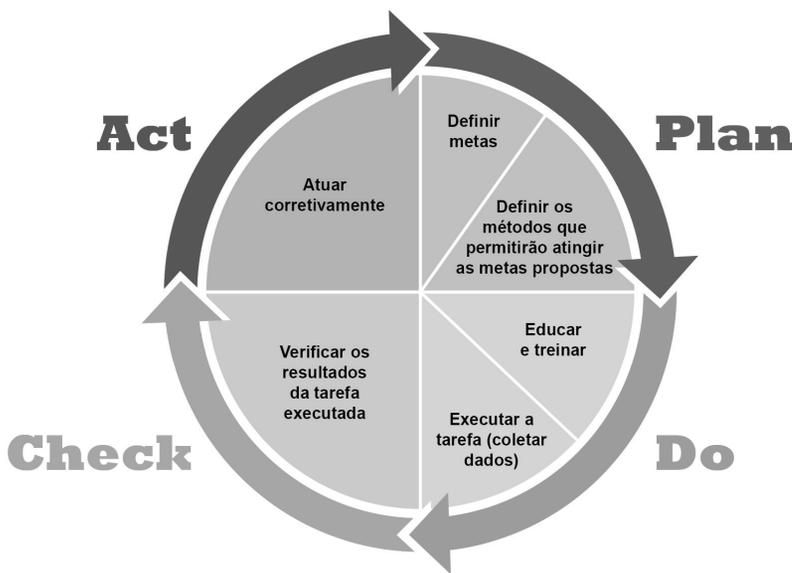


Figura 2.9: Ciclo PDCA de controle de processos. O “P” se aplica à manutenção de uma faixa de valores aceitáveis de qualidade, custos, prazo, etc. oriunda de procedimentos padrão de operação. Ou é aplicável a melhorias dos valores, por meio de processos específicos necessários para se atingir as novas metas.

Fonte: Campos (2004, p. 34).

Ainda que Campos (2004) defenda que o “P” focado na manutenção seja mais utilizado pelos operadores, visto que “o seu trabalho é essencialmente o de cumprimento de padrões” (p. 35), ao passo que o uso

para melhoria teria maior aplicação pelos gestores, tal separação não tem caráter discriminatório. Na realidade, são ações complementares na busca de patamares de excelência por parte da organização: se por um lado, se a organização tiver foco somente na manutenção, ela ficará estagnada em um patamar de desempenho.

Pior ainda, a atenção excessiva na aderência aos padrões e procedimentos fará com que a burocracia se torne mais importante que os resultados e a empresa começa e se perder no seu dia a dia e nas atividades rotineiras: repare, por exemplo, como isso é comum em diversas repartições públicas. Há um zelo enorme para que “tudo esteja correto”, mas, em contrapartida, há demora excessiva em qualquer atividade, falta de flexibilidade para ação (até mesmo para resolver problemas rotineiros), falta de compromisso com os resultados finais, etc. e, conseqüentemente, as necessidades da população acabam ficando em segundo plano. Ou seja, tudo fica “certo”, mas pouco eficiente e pouco eficaz.

Por outro lado, uma organização que se preocupe somente em “mudar e experimentar” corre o risco de ficar sem rumo e se perder em experiências, com muitas “tentativas e erros”, a cada vez fazendo as coisas de forma diferente. Desta forma, o avanço em termos de desempenho deve intercalar períodos de experimentação e busca de novas formas de fazer as coisas (novos processos) e/ou de fazer novas coisas (novos produtos ou serviços).

É necessário que a organização garanta estabilidade em seus processos e resultados, de forma a ter uma base firme sobre a qual possa buscar oportunidades de melhoria. Um documentário da série “Maravilhas modernas” do *History Channel*, intitulado “The Assembly Lines” (Linhas de montagem), relata um bom exemplo sobre tal aspecto: em uma fábrica japonesa, eram retirados 10% dos recursos produtivos (por exemplo, 10% do espaço disponível ou 10% dos trabalhadores) de uma linha de produção. Os trabalhadores se reuniam e buscavam formas de conseguir continuar a produzir na mesma quantidade, com menos recursos. Surgiam, então, ideias de melhorias dos processos de trabalho.

Tais ideias implicavam identificar formas mais simples, rápidas e fáceis de fabricar os produtos, pois não era uma questão de “correr” com a produção. Ou seja, eram buscadas formas de evitar movimentos desnecessários, deslocamentos além do mínimo necessário de materiais, pessoas e ferramentas, etc. Ou seja, buscava-se identificar toda

e qualquer forma de desperdício de recursos humanos ou materiais e de tempo, de forma a eliminá-los e, desta forma, produzir utilizando menos recursos.

Obviamente, havia uma preocupação de que tais mudanças não causassem impactos negativos na qualidade. Por isso, as mudanças eram testadas e havia um cuidado muito grande para que as novas formas de trabalho fossem disseminadas e rigorosamente cumpridas por todos, afinal, ao mudar a forma como o trabalho é feito, há riscos de que, durante o período de aprendizado e adaptação, erros aconteçam. Havia, assim, uma aplicação direta do PDCA de melhoria, seguida do PDCA de manutenção.

No mesmo documentário, era explicado que, após um período de estabilidade, em que os processos eram mantidos de acordo com o padrão e os resultados gerados, novamente a criatividade dos envolvidos era incentivada: mais uma vez, eram retirados 10% dos recursos e o ciclo de melhoria se repetia, seguido do PDCA de manutenção, e assim sucessivamente.

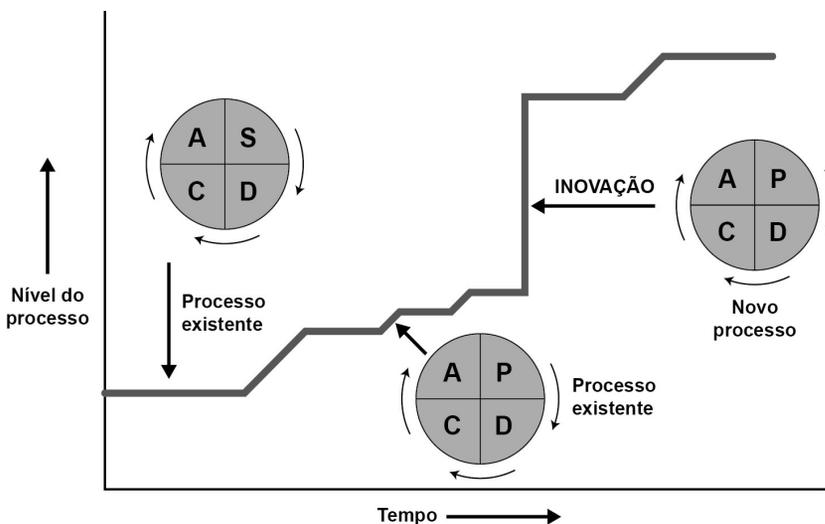


Figura 2.10: Conceito de melhoramento contínuo dos processos baseado na conjugação dos ciclos PDCA de manutenção e melhorias. Como você pode perceber, há fases em que o foco é a padronização (daí o “S”, de *standardize*, em inglês) dos processos, para manutenção e garantia dos resultados, aos quais se seguem ciclos de pequenas melhorias (*kaizen*) aplicados aos processos existentes ou mudanças substanciais, inovando com a criação e implementação de novos processos.

Fonte: Adaptado de Campos (2004, p.38).

Refleta um pouco sobre tal aspecto: o próprio processo de estudo, resolução de exercícios, etc. que você passa como estudante são exemplos de fixação de determinado conhecimento, antes de você avançar no estudo de novos tópicos. É algo bastante próximo ao que acabamos de discutir, não é mesmo? No contexto empresarial, o equilíbrio e a complementação dos ciclos de melhoria e manutenção são de grande importância para um avanço robusto e consistente rumo à excelência.

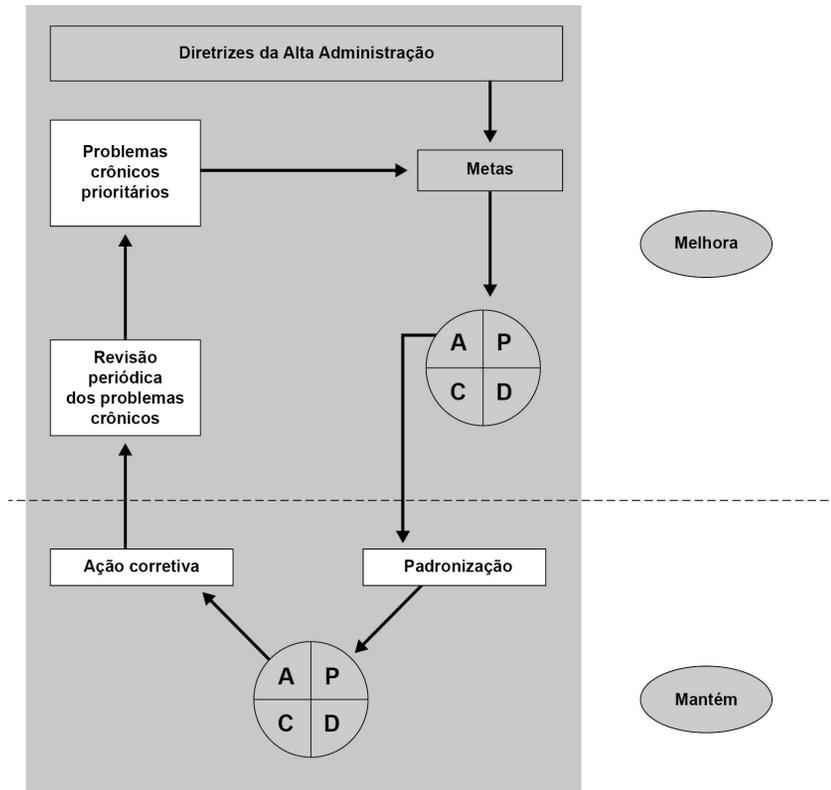


Figura 2.11: PDCA aplicado com os objetivos de manter e melhorar. As duas vertentes de aplicação do ciclo PDCA se complementam, permitindo que a organização possa avançar de forma segura na melhoria contínua de suas ações e resultados.

Fonte: Andrade (2003, p.13).

Campos (2004) detalha as etapas do PDCA para manter resultados:

Plan:

- definir os itens a serem controlados (ou seja, índices numéricos estabelecidos para medir os efeitos de cada processo sobre a qualidade), tomando como base as necessidades dos clientes internos e externos,

e sua faixa aceitável. Por exemplo, quantidade de itens quebrados durante a embalagem, que deve ser abaixo de 1%;

- definir os procedimentos padrão necessários para manter os resultados do processo. Ou seja, os fatores importantes dos processos que devem ser padronizados. Por exemplo, o passo a passo e os cuidados necessários durante a embalagem;
- nessa etapa, é importante se certificar que operadores e demais envolvidos conhecem as metas da rotina do trabalho, de tal forma que haja um critério para se saber se o resultado do trabalho é adequado ou não.

Do:

- treinar os executantes do processo no procedimento padrão, ou seja, no procedimento que foi definido em “*Plan*”;
- treinar os envolvidos para capacitá-los na coleta de dados;
- executar as tarefas de acordo com o que é prescrito nos procedimentos padrão (obs: de acordo com o autor, isso deve ser periodicamente auditado);
- nesta etapa, é necessário garantir que os operadores e demais envolvidos possam prover dados que permitam avaliar a adequação dos resultados da execução do trabalho.

Check:

- verificar (inspecionar) os itens de controle que foram definidos em “*Plan*”, os quais devem ser devidamente coletados, para compará-los com as faixas definidas como aceitáveis. Por exemplo, coletar a quantidade de quebras na embalagem e apurar se está abaixo de 1%;
- aqui, é relevante certificar-se de que os operadores e demais envolvidos sabem como inspecionar o trabalho e separar o que é bom do ruim.

Act:

- caso o resultado do “*Check*” mostre que os itens de controle estão dentro da faixa aceitável, a ação prevista é simplesmente manter os procedimentos atuais;

- por outro lado, caso haja alguma anomalia (não conformidade em relação aos padrões de verificação), os responsáveis devem ser acionados, para que iniciem as ações corretivas, de tal forma que haja correção no rumo e os resultados caminhem para faixas aceitáveis, eliminando as não conformidades;
- é de extrema importância que todas as anomalias sejam relatadas e registradas.

Já o PDCA para melhoria de resultados, por lidar com algo novo, é mais complexo.



Figura 2.12: Ciclo PDCA para melhorias. Também conhecido como QC Story (história do controle de qualidade), tem como diretriz ser um método estruturado de solução de problemas na empresa. Tal abordagem entende a existência de um “problema” a partir de um resultado indesejável.

Fonte: Adaptado de Campos (2004, p. 42).

O QC Story (PDCA para melhorias), método proposto pela JUSE, prevê as seguintes fases (KUME, 1993; CAMPOS, 2004):

Plan:

- identificação do problema: definir claramente o problema e reconhecer sua importância. A exploração do que é, de fato, problema, sua abrangência e impactos é de vital importância para o bom andamento do

PDCA. Trabalhar no “problema errado” leva ao uso indevido de recursos, perda de tempo e, pior, à não solução dos problemas;

- observação: investigar as características específicas do problema, com uma visão ampla e sob vários pontos de vista. Trata-se do aprofundamento da compreensão do problema: saber o que ele é, onde ocorre, como, quando, etc.;
- análise: descobrir as causas fundamentais. É um dos passos mais importantes do ciclo: identificar as causas-raiz, ao invés de somente os sintomas. Podemos fazer a analogia com uma consulta médica: não adianta saber que há uma dor, mas sim identificar o que a causa, para poder agir sobre elas. Inicialmente, estabelecem-se hipóteses (potenciais causas), as quais devem ser testadas, para serem validadas ou não como causas reais dos problemas;
- plano de ação: conceber um plano para bloquear as causas fundamentais. Ou seja, estabelecer o que fazer para atuar sobre as causas dos problemas, como um médico faz ao prescrever um tratamento a ser seguido para curar um paciente.

Do:

- ação: bloquear as causas fundamentais. Trata-se da execução do plano previamente concebido.

Check:

- verificação: comprovar se o bloqueio foi efetivo. Isso é feito, usualmente, a partir da apuração de que as ocorrências, ou seja, os efeitos indesejados cessaram. Por exemplo, um médico acompanha a evolução de um paciente ao longo do e após o tratamento, para se certificar de que ele está, de fato, curado. É necessário comparar os dados do problema, obtidos antes e depois da execução das ações, para apurar a efetividade da solução.

Act:

- padronização: prevenir contra o reaparecimento do problema. Ou seja, uma vez solucionado o problema, estabelecer as rotinas para que ele não volte a ocorrer. Trata-se de um passo que vincula o PDCA

de melhoria com o PDCA de manutenção, subsidiando a educação e o treinamento;

- conclusão: recapitular todo o processo de solução do problema para trabalho futuro. Trata-se de estabelecer um processo de lições aprendidas, não somente para evitar novas ocorrências, mas, também, para avançar em outros problemas, ou para outros patamares de desempenho, sem precisar “reinventar a roda”.

PDCA	Fluxograma	Fase do MASP	Objetivo
P	1	Identificação do problema	Definir claramente o problema e reconhecer a sua importância.
	2	Observação	Investigar as características específicas do problema com uma visão ampla e sob vários pontos de vista.
	3	Análise	Descobrir as causas fundamentais.
	4	Plano de ação	Conceber um plano para bloquear as causas fundamentais.
D	5	Ação	Bloquear as causas fundamentais.
C	6	Verificação	Verificar se o bloqueio foi efetivo.
	7	O bloqueio foi efetivo?	
A	8	Padronização	Prevenir contra o reaparecimento do problema.
	9	Conclusão	Recapturar todo o processo de solução do problema para trabalho futuro.

Figura 2.13: QC Story. Também conhecido como Método de Análise e Solução de Problemas (MASP), representa o PDCA para melhorias. Porém, é usualmente apresentado de forma linear, ao invés de um ciclo como o PDCA para manutenção.

Fonte: Adaptado de Campos (2004, p. 67).

“Como metodologia científica, a MASP faz uso de diferentes ferramentas que permitem organizar os dados e fatos, transformando-os em informações para auxiliar cada uma de suas fases” (ENAP, 2015, p. 7). As ferramentas habitualmente utilizadas na MASP/PDCA são mostradas na **Figura 2.12:**

PDCA	Fase do MASP	Ferramentas	
		Fatos e dados existentes	Fatos existentes
P	Estudo do processo	Dados históricos Análise de Pareto Fluxograma	Brainstorming Brainwriting
	Identificação do problema	Folha de Verificação Diagrama de Pareto	Votação de Pareto
	Observação	Análise de Pareto	4Q1POC
	Análise	Diagrama de Ishikawa Lista de Verificação Análise de Pareto Histograma Gráficos	Diagrama de Ishikawa Matriz GUT
	Plano de Ação	4Q1POC	Votação de Pareto Diagrama de Árvore
D	Execução	4Q1POC Reuniões participativas	4Q1POC Reuniões participativas
C	Verificação	Análise de Pareto Histograma	Lista de Verificação Diagrama de dispersão
	Bloqueio foi efetivo?		
A	Padronização	4Q1POC Diagrama de Árvore	4Q1POC Diagrama de Árvore
	Conclusão	4Q1POC Gráficos	4Q1POC Gráficos

Figura 2.14: Ferramentas da MASP/PDCA. As especificidades de cada fase do QC Story ou MASP demanda o uso de diferentes ferramentas: enquanto algumas são utilizadas para identificar a existência de um problema ou compreendê-lo, outras se prestam a identificar as possíveis causas-raiz, identificar potenciais soluções, suportar o desenvolvimento de um plano de ações, apurar a eficácia destas ações e compilar as lições aprendidas. Repare como algumas ferramentas fazem parte da lista das denominadas “sete ferramentas de Ishikawa” (vide Aula 1). Obs.: o 4Q1POC é mais conhecido como 5W2H.

Fonte: ENAP (2015, p. 8).

Você pode observar que o PDCA e suas expansões (QC Story/MASP) estabelecem um método abrangente e integrado de ações para a melhoria contínua das organizações: a ele se agregam ferramentas diversas e de uso específico, que permitem análises em cada uma de suas etapas e que garantem que as organizações gerenciem de forma mais robusta o seu dia a dia e sua rota ao sucesso e à sustentação no mundo dos negócios.

==== Atividades =====

Atendem aos objetivos 1 e 2

Preencha corretamente (P, D, C ou A) a classificação dos textos nos casos a seguir, considerando o ciclo PDCA (vide Figura 2.8).

1. Você mudou de dentista...

Texto	Classificação
Ficou encabulado: você estava 15 minutos atrasado.	
Foi e, chegando lá, deu de cara com um relógio na parede.	
Informou-se do endereço e planejou uma forma de chegar lá.	
Na consulta seguinte, você saiu um pouco mais cedo de casa e, desta vez, chegou no horário.	

2. Querendo controlar seu peso...

Texto	Classificação
Certa vez, seu peso tinha subido além dos valores habituais.	
Comer moderadamente e fazer caminhada três vezes por semana.	
Estava seguindo o regime a que se propusera.	
Manter o peso em torno dos 70 kg.	
Periodicamente, você se pesa numa farmácia perto de casa.	
Pesar-se sempre com as mesmas roupas.	
Você estava se pesando com roupa muito pesada.	

Respostas comentadas:

1. Você mudou de dentista...

Texto	Classificação	Comentários
Ficou encabulado: você estava 15 minutos atrasado.	C	Você comparou o resultado com sua expectativa e decidiu que precisava mudar.
Foi e, chegando lá, deu de cara com um relógio na parede.	D	Você executou o plano e mediu o resultado (olhou as horas).
Informou-se do endereço e planejou uma forma de chegar lá.	P	Você estabeleceu um plano, baseado numa expectativa de tempo de trajeto.
Na consulta seguinte, você saiu um pouco mais cedo de casa e, desta vez, chegou no horário.	A	Você mudou o seu horário de saída de casa.

2. Querendo controlar seu peso...

Texto	Classificação	Comentários
Certa vez, seu peso tinha subido além dos valores habituais.	C	Você comparou o resultado com sua expectativa, verificou o problema e descobriu a causa.
Comer moderadamente e fazer caminhada três vezes por semana.	P	Você estabeleceu um plano, baseado numa expectativa de manter o peso.
Estava seguindo o regime a que se propusera.	D	Você executou o plano e mediu o resultado.
Manter o peso em torno dos 70 kg.	P	Você estabeleceu um plano, baseado numa expectativa de manter o peso.
Periodicamente, você se pesa numa farmácia perto de casa.	D	Você executou o plano e mediu o resultado.
Pesar-se sempre com as mesmas roupas.	A	Você decidiu mudar seu padrão.
Você estava se pesando com roupa muito pesada.	C	Você comparou o resultado com sua expectativa, verificou o problema e descobriu a causa.

Conclusão

O ciclo PDCA, seja voltado à manutenção ou à melhoria, é um método estruturado utilizado por diversas organizações para o controle e a melhoria da qualidade. A lógica de se planejar antes de executar, de forma a identificar necessidades, ações, prazos e recursos para o atingimento de objetivos, estabelece uma forma ordenada e robusta para gerar resultados adequados. Além disso, estabelecer a rotina de verificar se os resultados da execução estão alinhados com as metas planejadas, de tal forma que seja possível tomar decisões para manter ou corrigir o rumo, faz com que essa simples ferramenta tenha um grande poder de levar as organizações a patamares de excelência.

Resumo

Por mais avançados que sejam os processos produtivos, há diferenças entre peças e componentes produzidos pelo mesmo processo. Da mesma forma, ocorrem variações nas atividades que são executadas. De uma forma geral, se tais variações forem pequenas, não chegam a causar qualquer tipo de problema.

No entanto, variações mais substanciais podem ser causa de problemas na execução do trabalho, bem como de diferenças nos produtos, os quais podem impedir o funcionamento adequado. Desta forma, é necessário monitorar os processos e garantir que as variações sejam limitadas. Para tanto, é utilizado o ciclo PDCA (do inglês *plan*/planejar – *do*/executar – *check*/verificar – *act*/agir) de manutenção, que prevê definir previamente as metas do processo, bem como os processos para atingir tais metas (“P”), ao que se segue educar ou treinar o pessoal envolvido no citado processo, para que eles o executem conforme planejado (“D”), verificando se os resultados estão de acordo com o planejado (“C”) e, a partir daí, decidindo os próximos passos.

Mas o PDCA pode ser utilizado, também, para melhorar o desempenho: trata-se do método denominado *QC Story*, que tem como foco a solução de problemas (por isso é conhecido, também, como Método de Análise e Solução de Problemas (MASP). Para tanto, o ciclo prevê que haja a identificação do problema, sua observação e a análise do processo, para que seja possível identificar as causas-raiz e, conseqüentemente, elaborar um plano de ação. Este é, então, executado e os resultados,

verificados. A partir daí, padroniza-se o novo processo e são discutidas as conclusões do ciclo, incluindo as lições aprendidas.

Leituras recomendadas

ALBUQUERQUE, Ananélia Claudia Rodrigues de Queiroz. *Avaliação da aplicação do ciclo PDCA na tomada de decisão em processos industriais*, 2015, 107 f. Dissertação (Mestrado em Engenharia). Belém: Universidade Federal do Pará, 2015. Disponível em: [ttp://ppgpep.propesp.ufpa.br/ARQUIVOS/dissertacoes/Dissertacao2015-PPGEP-MP-AnaneliaClaudiaRodriguesdeQueirozAlbuquerque.pdf](http://ppgpep.propesp.ufpa.br/ARQUIVOS/dissertacoes/Dissertacao2015-PPGEP-MP-AnaneliaClaudiaRodriguesdeQueirozAlbuquerque.pdf). Acesso em: 4 ago. 2018.

LEONEL, Paulo Henrique. *Aplicação prática da técnica do PDCA e das ferramentas da qualidade no gerenciamento de processos industriais para melhoria e manutenção de resultados*, 2008, 85 f. Monografia (Graduação em Engenharia de Produção). Juiz de Fora: Universidade Federal de Juiz de Fora, 2008. Disponível em: http://www.ufjf.br/ep/files/2014/07/2008_1_Paulo-Henrique-Leonel.pdf. Acesso em: 4 ago. 2018.

NASCIMENTO, Adriano Fagner Gonçalves. *A utilização da metodologia do ciclo PDCA no gerenciamento da melhoria contínua*, 2011, 38 f. Monografia (Especialização). São João Del Rei: Faculdade Pitágoras, 2011.

Informação sobre a próxima aula

Na próxima aula, iniciaremos os estudos das ferramentas para o controle da qualidade: estratificação, folha de verificação e diagrama de dispersão.

Referências Bibliográficas

ABBUD, C. Projeto de métodos de trabalho: conceito geral. In: KLIPPEL, A. F. et al. (org.). *Engenharia de métodos*. 2. ed. Porto Alegre: SAGAH, 2017, p. 33-40.

ANDRADE, F. F. *O método de melhorias PDCA*, 2003, 169 f. Dissertação (Mestrado em Engenharia), Universidade de São Paulo, São Paulo, 2003.

CAMPOS, V. F. *TQC: controle da qualidade total (no estilo japonês)*. São Paulo: INDG, 2004.

CLARK, K.; FUJIMOTO, T. *Product Development Performance: Strategy, Organization and Management in the World Auto Industry*. Boston: Harvard Business School Press, 1991.

DEMING, W. E. *Out of the Crisis*. 2. ed. Massachusetts: Mit Press, 2000.

Escola Nacional de Administração Pública – ENAP. *Análise e melhoria de processos: metodologia MASP*. Brasília: ENAP, 2015.

GARVIN, D. A. What Does “Product Quality” Really Mean? *MIT Sloan Management Review*: Outono 1984, October 15, 1984. Disponível em: <https://sloanreview.mit.edu/article/what-does-product-quality-really-mean/>. Acesso em: 16 maio 2018.

GARVIN, D. A. *Gerenciando a qualidade*. 3. ed. Rio de Janeiro: QualityMark, 2002.

KUME, H. *Métodos estatísticos para melhoria da qualidade*. 7. ed. São Paulo: Gente, 1993.

MARAVILHAS MODERNAS: Assembly Line. 6. Temporada, 33. Episódio. Criação: Bruce Nash. Elenco: John Applegate, Steve Babson, Bob Casey. History Channel, 19 out. 2000.

MUNDIM, A. et al. Aplicando o cenário de desenvolvimento de produtos em um caso prático de capacitação profissional. *Gestão & Produção*, São Carlos, v. 9, n. 1, p. 1-16, abr. 2002.

PROJECT MANAGEMENT INSTITUTE – PMI. *PMBOK – Um guia do conhecimento em gerenciamento de projetos*. 5. ed. São Paulo: Saraiva, 2013.

ROCHA, H. M. *Projeto de plantas industriais*. Porto Alegre: Sagah, 2017, 150 p.

WALTON, M. *Made in USA: o método Deming de administração*. Rio de Janeiro: Saraiva, 1989, 276 p.

Aula 3

Ferramentas para o controle da qualidade: estratificação, folha de verificação e diagrama de dispersão

Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. saber como utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. saber como estratificar os dados e qual a sua importância;
3. conhecer uma folha de verificação;
4. entender um diagrama de dispersão.

Pré-requisitos

Funções estatísticas, conteúdo abordado nas disciplinas Estatística I e II, bem como o ciclo PDCA, trabalhado na Aula 2 da presente disciplina.

Introdução

Todo estudo sobre qualidade, sua manutenção e melhoria contínua, faz uso de ferramentas. São ferramentas que auxiliam na identificação e análise de problemas e nos mostram caminhos para melhorar o desempenho de produtos, processos e das próprias empresas. O conhecimento sobre tais ferramentas nos municia com recursos para desenvolver um processo estruturado de trabalho no que tange ao controle da qualidade.

É isso que você estudará aqui, começando pela apresentação das ferramentas da qualidade, iremos detalhar três delas: a estratificação, a folha de verificação e o diagrama de dispersão. Bons estudos!

O controle da qualidade depende de processos estruturados e integrados, para garantir que resultados sustentáveis sejam alcançados e o sucesso das organizações aconteça. Nesse sentido, a utilização do ciclo PDCA, seja para manutenção ou para melhoria (vide Aula 2) permite a construção de uma base robusta para a construção, o fortalecimento e a contínua melhoria da qualidade das organizações.

Mas a base, por si só, não é suficiente para gerar os benefícios esperados: ela deve sustentar os instrumentos que farão com que isso ocorra. E tais instrumentos são as denominadas ferramentas para o controle da qualidade (também conhecidas por sua forma reduzida, “ferramentas da qualidade”, ou ainda, “as sete ferramentas da qualidade”), que são:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de Pareto;
- diagrama de causa e efeito;
- histograma;
- gráficos de controle.



Figura 3.1: Sete ferramentas. Da mesma forma que nas oficinas, fábricas, etc. há diferentes ferramentas para diferentes usos e necessidades, a qualidade dispõe de suas ferramentas, as quais são selecionadas e utilizadas para atender a necessidades específicas. Elas formam um conjunto robusto e poderoso para o controle e a melhoria contínua da qualidade.

Fonte: <https://pixabay.com/pt/ferramentas-trabalho-repara%C3%A7%C3%A3o-2145771/>

Nesta aula, você será apresentado às sete ferramentas e aprofundará seus conhecimentos sobre as três primeiras (estratificação, folha de verificação e diagrama de dispersão).

Ferramentas para o controle da qualidade

O controle da qualidade exige, além da vontade dos envolvidos, o uso de processos estruturados. Um modelo bastante utilizado para tal estruturação é o do ciclo PDCA, isto é, o ciclo de Planejamento, Execução, Controle e Ação. O modelo original, denominado ciclo de Shewhart, previa que nas etapas de planejamento fossem feitas, dentre outras, as seguintes perguntas:

- Quais são os dados de que dispomos?
- É preciso fazer novas observações?

E, também, que fossem buscados os dados disponíveis e decidir como seriam usadas as observações. Também Campos (2004) detalha

as etapas do PDCA para manter resultados e, no que tange ao planejamento, destaca a necessidade de medir os efeitos de cada processo sobre a qualidade, bem como inspecionar os dados coletados e verificar se estão dentro da faixa aceitável. Já no PDCA para melhoria de resultados, o autor alerta ser necessário investigar as características específicas do problema, para compreendê-lo e analisá-lo, de modo a descobrir suas causas fundamentais, isto é, as causas-raiz.

Sem a coleta de dados e informações e sem a análise destas, não é possível iniciar ações de contenção, correção e prevenção, pelo simples fato de que não sabemos o que está ocorrendo nem por quê. Assim, como você pode perceber, o controle da qualidade é altamente dependente da busca e análise de informações diversas. E é neste ponto que as ferramentas de controle da qualidade mostram a sua contribuição: elas se prestam exatamente a tal finalidade.

É importante destacar que não somente encontramos diferentes denominações para este conjunto de ferramentas (ferramentas para o controle da qualidade, ferramentas da qualidade, ferramentas estatísticas da qualidade, sete ferramentas da qualidade, sete ferramentas básicas da qualidade, etc.), mas também há pequenas variações na própria lista das ferramentas. Por exemplo, você deve recordar que, na Aula 1, foram apresentadas as denominadas sete ferramentas de Ishikawa, quais sejam:

1. gráfico de Pareto;
2. folhas de verificação;
3. fluxogramas;
4. diagrama de causa-efeito;
5. histogramas;
6. gráfico de dispersão;
7. cartas de controle.

Quais as diferenças que você encontra entre as duas listas?

Além de pequenas diferenças na nomenclatura (por exemplo, cartas de controle *versus* gráficos de controle, ou gráficos de dispersão *versus* diagrama de dispersão), o que você deve ter percebido é que os fluxogramas (nas ferramentas de Ishikawa), que compõem, também, a lista

das ferramentas da American Society for Quality (ASQ), são substituídos pela estratificação. Adotaremos esta versão na nossa aula, seguindo as bases de Peinado e Graeml (2007) e Carpinetti (2012).

Vamos descrever brevemente cada uma destas sete ferramentas e sua utilização no controle da qualidade de processos:

Estratificação: Trata-se da segmentação dos dados, isto é, a classificação dos dados em grupos, de tal forma que seja possível estudar cada grupo separadamente e verificar se eles têm alguma característica específica, tendência, etc. Sem a estratificação, há o risco de as diversas variações existentes em todos os grupos se sobreponem e não ser possível identificar a ocorrência de determinados fenômenos.

Folha de Verificação: Nada mais é que um formulário utilizado para coletar dados e informações diversas. Não há um padrão único para tal formulário: sua configuração depende basicamente do tipo de informação que desejamos coletar, bem como a forma como estabelecemos sua estratificação.

Diagrama de dispersão: É um gráfico que mostra como duas variáveis se comportam, ou seja, se há alguma relação entre elas (por exemplo, quando uma aumenta de valor, o que acontece com a outra?). Com isso, é possível avaliar se há relações de causa e efeito entre variáveis relacionadas à qualidade de produtos e processos.

Gráfico de Pareto: É também um gráfico utilizado para apresentar a quantificação de ocorrências diversas (dependendo de como foi feita a estratificação dos dados). Por meio da apuração das quantidades das ocorrências, é possível identificar quais são prioritárias para análise e ações em prol da qualidade.

Diagrama de Causa e Efeito: Representa graficamente “ramos” de potenciais causas-raiz de um problema. Sua construção direciona as análises e o processo mental para identificação das diversas potenciais causas de um mesmo problema.

Histograma: Ferramenta que representa graficamente as distribuições de frequência de determinada medida. Por meio de tal representação, é possível identificar anomalias. Por exemplo, variação excessiva, deslocada “para um lado”, distribuição irregular, etc.

Gráficos de Controle: Gráficos que indicam limites nas variações de determinado processo: variações consideradas normais ficam “dentro dos limites”, ao passo que variações excessivas (além dos limites estabelecidos) indicariam alguma anomalia no processo, disparando, assim, um processo de investigação e análise.

Como você pode perceber, as ferramentas têm forte viés de coleta e análise dos dados, utilizando para isso recursos visuais, que tornam os processos de trabalho relacionados ao controle da qualidade mais intuitivo, além de permitir fácil visualização de inadequações de qualquer tipo. Vamos discutir em mais profundidade cada uma destas ferramentas.

Estratificação

Campos (2004) define estratificação como a ação de dividir um problema em estratos, ou seja, camadas de problemas de origens diferentes, facilitando, portanto, a identificação da origem do problema. A lógica é que, sem tal divisão, temos dificuldades em identificar fenômenos que envolvem as atividades na organização e seus impactos sobre a qualidade. Veja, por exemplo, a situação trazida por Santos (2009), referente às reclamações recebidas por um hospital: em determinado período de tempo foram recebidas 200 reclamações e você precisa tomar ações para reverter tal situação. Surge, assim, a dúvida: por onde começar?

Obviamente, a informação sobre o total de 200 reclamações nos diz muito pouco e, naturalmente, sua primeira ação será a de tentar compreender os tipos de reclamações que chegam. No entanto, imagine que não haja detalhamento sobre elas: os clientes e pacientes insatisfeitos fizeram as reclamações e elas foram tão somente contabilizadas e totalizadas (chegando às 200) e nada mais se sabe sobre elas. Seria algo muito complicado, não é mesmo? Faltam informações para você poder começar a atuar, pois as reclamações podem ter qualquer origem, qualquer causa e você não tem onde buscar tais detalhes.

A situação descrita reflete o que ocorre quando não há a estratificação, isto é, quando os dados não são segmentados. Agora, observe o que aconteceria se as informações tivessem sido estratificadas por dia da semana, por setores do hospital e pelo horário em que as reclamações ocorreram:

Tabela 3.1: Reclamações estratificadas por dia da semana

Dia da semana	Quantidade
Segunda-feira	14
Terça-feira	7
Quarta-feira	12
Quinta-feira	21
Sexta-feira	89
Sábado	48
Domingo	9
Total	200

Fonte: Adaptado de Santos (2009).

É importante ter as informações sobre reclamações estratificadas desta forma? Bem, se não houvesse diferença significativa entre os dias, a resposta seria não. Mas, como você pode observar, há um acúmulo de reclamações em alguns dias e isso pode nos ajudar a entender o que está acontecendo, ou seja, qual fenômeno causa tal variação. Repare que as sextas-feiras são responsáveis por quase metade de todas as reclamações. Observe, também, que, se totalizarmos as reclamações das sextas-feiras e dos sábados, temos mais de 2/3 de todas as reclamações.

Ou seja, há algo ocorrendo nestes dias específicos que tem causado um volume significativo de reclamações. Não sabemos o que é, mas o simples fato de sabermos que há tal acúmulo (o que seria impossível, se as informações não tivessem sido estratificadas) já nos dá um sinal de alerta e uma direção de por onde devemos iniciar nossa investigação e as ações de melhoria da qualidade.

Veja, também, o que a estratificação por setores mostra:

Tabela 3.2: Reclamações estratificadas por setores do hospital

Setores do hospital	Quantidade
Marcação de consulta	80
Ambulatório	60
Laboratórios	32
Internação	24
Alimentação	2
Serviço social	2
Total	200

Fonte: Adaptado de Santos (2009).

Para tornar mais evidente as variações, os setores são apresentados em ordem decrescente da quantidade de reclamações. O que você percebe? Há setores que merecem mais atenção se quisermos melhorar a qualidade do hospital? Note que o setor de marcação de consulta é responsável por 40% das reclamações, enquanto o ambulatório, por mais 30%, ou seja, tais setores merecem o foco de nossa investigação e análise das razões que levam a tantas reclamações.

Note, então, que nossa investigação começa a ser direcionada para compreender o que acontece nas sextas-feiras e nos sábados nos setores de marcação de consultas e ambulatório: será que há poucas pessoas trabalhando nestes dias em tais setores e que, por isso, não conseguem atender às demandas? Será que os funcionários que lá atuam estão desempenhando adequadamente suas funções? Começamos a ter trilhas de investigação a partir dos achados que fizemos e que só foram possíveis por meio da estratificação. Vejamos se a estratificação nos mostra algo mais sobre as reclamações, observando os horários:

Tabela 3.3: Reclamações estratificadas por horário

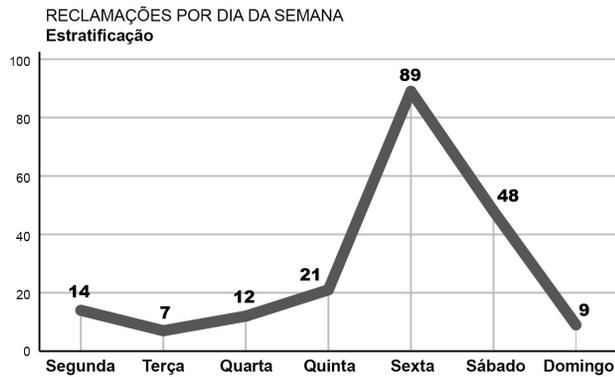
Horário	Quantidade
0h – 4h	39
4h – 8h	28
8h – 12h	32
12h – 16h	34
16h – 20h	31
20h – 0h	36
Total	200

E agora, há algum horário que chame a atenção e que mereça um esforço de investigação? Como você pode perceber, ainda que a quantidade de reclamações não permaneça estável, não parece existir, de fato, algum horário que possamos dizer ser um pico. Consequentemente, ao menos com base nas informações coletadas, nada podemos inferir sobre o efeito dos horários sobre o quantitativo das reclamações.

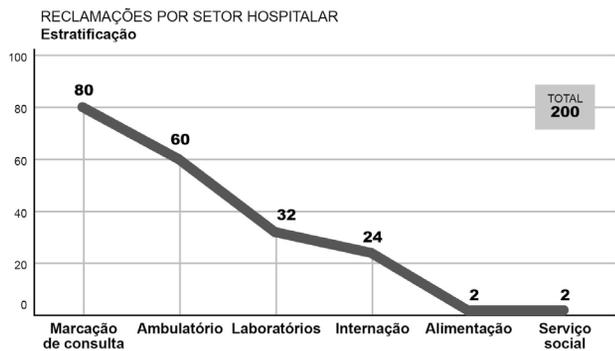
Isso significa que cometemos algum engano? Que nossa análise não foi adequada? Absolutamente! A estratificação é utilizada para que possamos identificar padrões ou fenômenos, quando eles existem. No exemplo do hospital, foi possível identificar os dias da semana e os setores que deverão ser foco de investigação para identificar as causas-raiz das reclamações. Entretanto, uma investigação sobre os horários não nos parece ser promissora, então não seria adequado seguirmos tal trilha. Observe que chegar à conclusão de que alguma coisa não é relevante não é perda de tempo: seria perda se gastássemos tempo e recursos para investigar algo que não nos levasse a lugar algum.

Assim, a estratificação se mostra benéfica quando nos aponta caminhos a seguir, mas, também, quando nos aponta caminhos de investigação que não parecem ser relevantes, afinal, a estratificação diagnostica e nos direciona para desenvolver ações nas categorias onde os problemas estejam e sejam mais marcantes (SANTOS, 2009). Em caso de dúvida, o autor recomenda que as informações sejam colocadas em gráficos, que permitirão visualizar mais facilmente padrões e comportamentos. Vejamos, agora, a representação gráfica das três formas de estratificação do exemplo das reclamações do hospital:

(a)



(b)



(c)

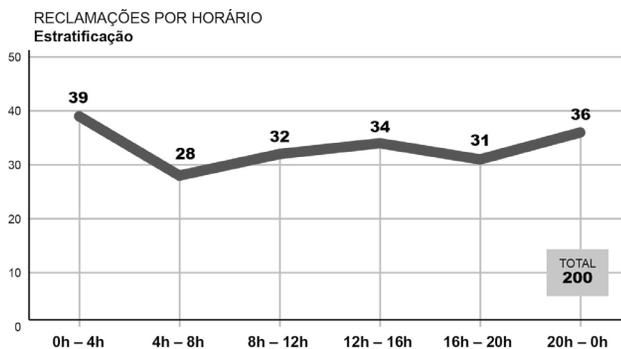


Figura 3.2: Gráficos das reclamações estratificados por dia da semana (a), setor (b) e horário (c). Com eles, fica mais evidente que há diferenças significativas na quantidade de reclamações, dependendo do dia da semana e do setor, mas que isso não é perceptível em diferentes horários.

Você já deve ter preenchido fichas e pesquisas de opinião em que lhe perguntam sua idade, seu nível de escolaridade, gênero, etc. Reflita por

um momento: se, por exemplo, uma operadora de TV a cabo pergunta a sua idade, escolaridade e gênero, de que forma as suas respostas lhe seriam úteis? Ela poderia identificar similaridades nas preferências de pessoas na mesma faixa de idade, etc. e, a partir daí, estabelecer programação específica, bem como oferecer pacotes de canais e programação para públicos específicos, o que seria muito mais efetivo do que gerar ações iguais para todos, não é mesmo?

A lógica é a mesma utilizada para investigar problemas: a estratificação da população que responde a tais pesquisas pode indicar algum padrão (ou não). No entanto, ainda que a estratificação seja uma poderosa ferramenta da qualidade, por indicar características associadas ao fenômeno que se tenta explicar, Santos (2009, p.19) alerta que, “se nenhuma característica se destaca, deve-se procurar por outras categorias, pois isto indica que ainda não foi possível identificar a categoria que contém o problema”. As categorias de estratificação, ou seja, os fatores de estratificação, podem ser diversas:

- **Local:** diferentes postos de trabalho, linhas de produção, locais de venda e uso, etc.;
- **Pessoas:** diferentes operadores ou instaladores, etc.;
- **Tempo:** horário, dia da semana, dia do mês, mês, turno, etc.;
- **Tipo:** tipo de defeitos, de produtos, de defeitos, máquinas, matérias primas, etc.

Folha de verificação (ou lista de verificação, ou check-list)

De acordo com Christo (2017, p. 9): “A estratificação só pode ser realizada quando a origem dos dados que estão sendo utilizados na solução do problema de interesse puder ser identificada [...]. É importante registrar todos os fatores de estratificação que sofrem alterações durante a coleta de dados”. Para tal registro/coleta de informações, é desenvolvida a folha de verificação, “um formulário planejado que facilita a coleta e análise de dados, gerando informação e servindo como início da maioria dos controles de processo” (LOZADA, 2017, p. 14), que pode ser tanto impresso quanto em formato eletrônico/digital.

Conforme o documento é “aplicado repetidas vezes na coleta de dados, são gerados históricos de informações sobre determinada tarefa ou

processo, permitindo que sejam verificados comportamentos ou tendências, viabilizando a tomada de ações corretivas e auxiliando no planejamento dos ciclos de melhorias” (LOZADA, 2017, p.14-15). Não há um formato único para as folhas de verificação. Podem ser planilhas, quadros, tabelas, lidando com variáveis quantitativas (contínuas ou discretas) e qualitativas (CHRISTO, 2017), para verificar a distribuição de um item de controle de um processo produtivo, para classificar, para verificar a localização de defeitos, para identificar causas e efeitos, dependendo das necessidades de coleta de informações, bem como da estratificação que foi definida, como você pode ver nos exemplos a seguir.

Empresa:										
Estágio de fabricação:										
Inspetor:					Data:					
	Desvio	Quantidade de peças								Frequência
					5				10	
	0,0100									
	0,0090									
	0,0080									
	0,0070									
	0,0060									
Especificação	0,0050	X								1
	0,0040	X	X							2
	0,0030	X	X	X						3
	0,0020	X	X	X	X	X	X			6
	0,0010	X	X	X	X	X	X	X		8
1000	0,0000	X	X	X	X	X				5
	-0,0010	X	X	X	X	X				5
	-0,0020	X	X	X	X					4
	-0,0030	X	X	X						3
	-0,0040	X	X							2
Especificação	-0,0050	X								1
	-0,0060									
	-0,0070									
	-0,0080									
	-0,0090									
	-0,0100									
										Total
										40

Figura 3.3: Folha de verificação para distribuição de um processo de produção. São registradas as variações em um processo de usinagem cuja especificação é de $1.000 \pm 0,005$ mm. Após o processo de usinagem da peça é feita a medição, marcando um “X” na célula correspondente. Fonte: Adaptado de Ramos, Almeida e Araújo (2013, p. 8).

Produto: Copos de cristal						
Estágio de fabricação: Final						
Total inspecionado: 2585 copos						
Inspetor:				Data:		
Defeitos	Marcas					Subtotal
Trincado						16
Quebrado						12
Deformado						21
Manchado						10
Outros						03
Total						62

Figura 3.4: Folha de verificação para item defeituoso. Utilizada no processo de inspeção final de fabricação de copos de cristal de uma indústria. Sempre que observado um defeito, o responsável faz uma anotação, verificando ao fim do período a quantidade e os tipos de defeitos ocorridos no processo.

Fonte: Adaptado de Ramos, Almeida e Araújo (2013, p. 9).

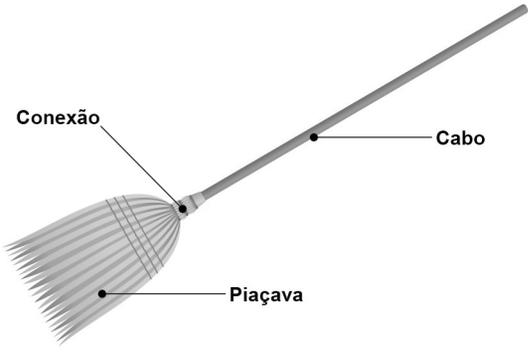
Folha de localização de defeitos em vassouras					
No do produto:			Data:		
Material:			Inspetor:		
Fabricante:					
Esquema:					
					
Matriz de localização de defeitos					
Defeitos	Lote 1	Lote 2	Lote 5	Lote 4	Total
Cabo					
Conexão					
Piaçava					
Total					

Figura 3.5: Folha de verificação para localização de defeitos. O inspetor identifica o quantitativo de defeitos em cada uma das três partes específicas do produto por lote inspecionado, verificando – ao fim do período – a quantidade de defeitos por local e o lote em que os defeitos ocorreram.

Fonte: Adaptado de Ramos, Almeida e Araújo (2013, p. 9) e <https://pixabay.com/pt/vassoura-limpeza-%C3%A9-escrever-limpar-1428449/>.

Empresa:													
Processo:													
Inspetor:										Data:			
Equipamento	Trabalhador	Dia da semana										Subtotal	Total
		Segunda		Terça		Quarta		Quinta		Sexta			
		M	T	M	T	M	T	M	T	M	T		
Tear 1	A												
	B												
Tear 2	C												
	D												
Subtotal													
Total													

Figura 3.6: Folha de verificação de causas. O inspetor identifica o quantitativo de problemas em dois teares, sendo cada um operado alternadamente por dois trabalhadores, nos turnos da manhã (M) e da tarde (T), de segunda até sexta-feira. No final da semana, é verificada a quantidade de defeitos por tear, por trabalhador, por turno e por dia da semana.

Fonte: Adaptado de Ramos, Almeida e Araújo (2013, p. 10).

Data:			
Nº 00582			
Restaurante X			
Dê sua opinião			
Pratos			
Sobremesas			
Atendimento			
Sugestões:	_____ _____ _____ _____		

Figura 3.7: Folha de verificação para satisfação de cliente. O cliente opina sobre cada um dos itens identificados como primordiais pela administração do restaurante, sendo possível totalizar as opiniões favoráveis ou desfavoráveis dos clientes.

Fonte: Adaptado de Ramos, Almeida e Araújo (2013, p. 11) e <https://pixabay.com/pt/emoji-smilie-whatsapp-emo%C3%A7%C3%A3o-rir-2762568/>.

Para correta utilização das folhas de verificação, é importante treinar as pessoas envolvidas no processo de obtenção de dados, a respeito da frequência e do método utilizado para realizar as medidas, e também as conscientizando da importância deste trabalho (CHRISTO, 2017). No entanto, como apontado por Silva (2018), as listas de verificação têm como limitação o fato de que se baseiam em uma lista de fatores conhecidos e esperados. Desta forma, há a possibilidade de situações não pensadas acontecerem e não serem detectadas.

As novas ocorrências devem ser incorporadas às listas, de tal forma que sejam constantemente atualizadas. Quando da implementação e a cada atualização, é recomendado que sejam feitos pré-testes (CHRISTO, 2017), de forma a garantir que haja compreensão e uso adequado.

Diagrama de Dispersão (ou diagrama de correlação)

O diagrama de dispersão é um gráfico utilizado para visualizar como duas variáveis estão relacionadas, isto é, se há algum tipo de influência de uma sobre a outra. Por exemplo, verificar se o aumento dos valores de uma variável faz com que outra também aumente, ou diminua, se não houver qualquer influência. Veja, por exemplo, o gráfico a seguir, que mostra a frequência de funcionamento de um equipamento (eixo x) e a quantidade de defeitos ocorridos (eixo y). Você diria que o aumento da frequência parece fazer com que ocorram mais defeitos?

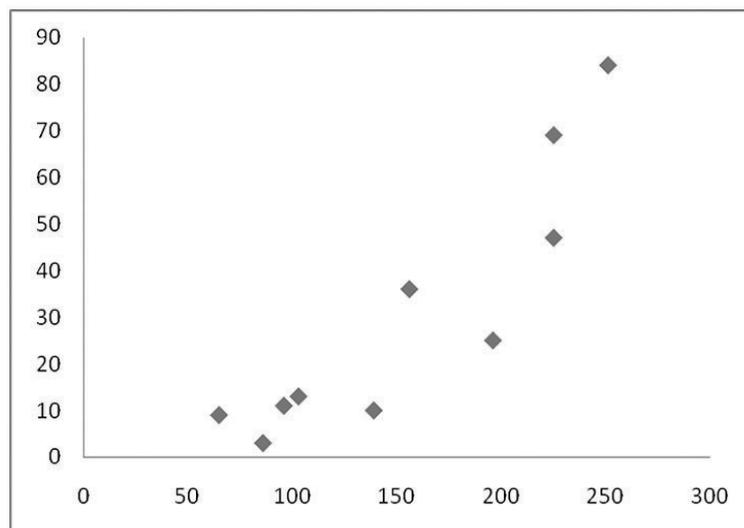


Figura 3.8: Gráfico de dispersão frequência de funcionamento x quantidade de defeitos. Perceba que, quanto maior a frequência, maior a quantidade de defeitos. Assim, é possível inferir que a frequência de funcionamento tem influência sobre a quantidade de defeitos do equipamento.

Por outro lado, veja como se comportam os defeitos (eixo y) com relação à umidade relativa do ar (eixo x): que conclusão você tira sobre essas variáveis?

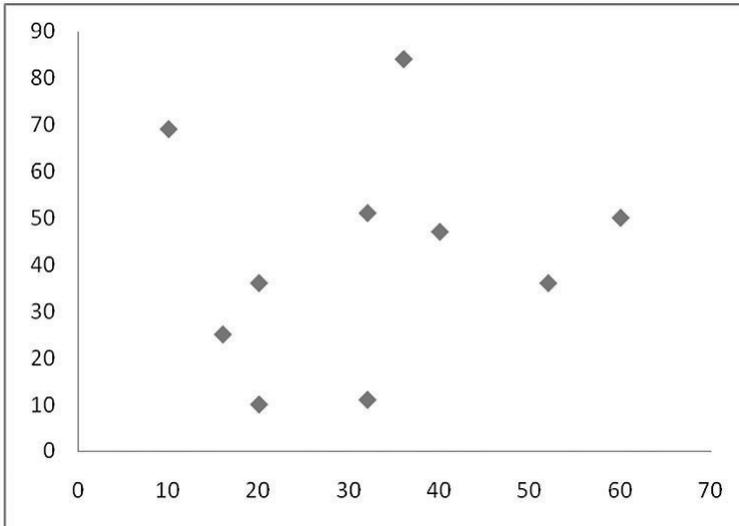


Figura 3.9: Gráfico de dispersão da umidade relativa do ar x quantidade de defeitos. Não parece haver qualquer relação entre as variáveis, isto é, parece serem variáveis independentes: uma não afeta a outra.

Você deve ter percebido que no gráfico de frequência x quantidade de defeitos, os pontos estão parcialmente “alinhados”, mostrando que as variáveis “andam juntas”, como pode ser visto no próximo gráfico, em que a linha imaginária é adicionada ao gráfico. Essa linha recebe o nome de “linha de tendência”.

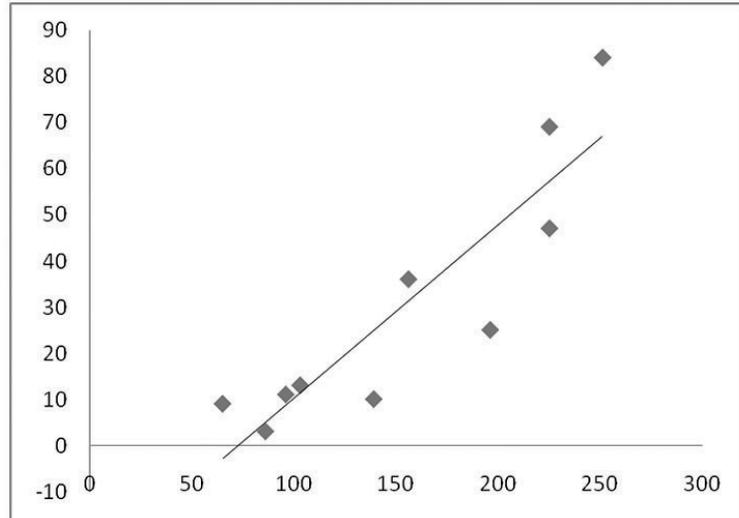


Figura 3.10: Gráfico de dispersão frequência de funcionamento x quantidade de defeitos com linha de tendência. A linha de tendência mostra uma aproximação do que ocorre com os valores das variáveis: como ela está inclinada “para cima”, indica que o aumento de uma variável influenciaria o aumento da outra. Caso a inclinação fosse “para baixo”, continuaria havendo relação entre as variáveis, porém, o aumento de uma causaria a diminuição da outra.

Mas, e no caso do gráfico umidade relativa do ar x quantidade de defeitos, conseguimos perceber a existência de uma linha desse tipo? Não: os pontos estão “espalhados” (ou seja, dispersos), sem mostrar qualquer tipo de comportamento específico que indique uma relação entre as variáveis. Essa “dispersão” (ou, ao contrário, a falta dela, quando há algum alinhamento perceptível entre os pontos) é que dá o nome a este tipo de gráfico.

Você deve ter percebido que no gráfico de frequência x quantidade de defeitos, os pontos estão parcialmente “alinhados”, mostrando que as variáveis “andam juntas”, como pode ser visto no próximo gráfico, em que a linha imaginária é adicionada ao gráfico. Essa linha recebe o nome de “linha de tendência”: quanto mais próximos os pontos estão de uma linha imaginária, mais forte é a relação e influência entre as duas variáveis mostradas no gráfico (LOZADA, 2017).

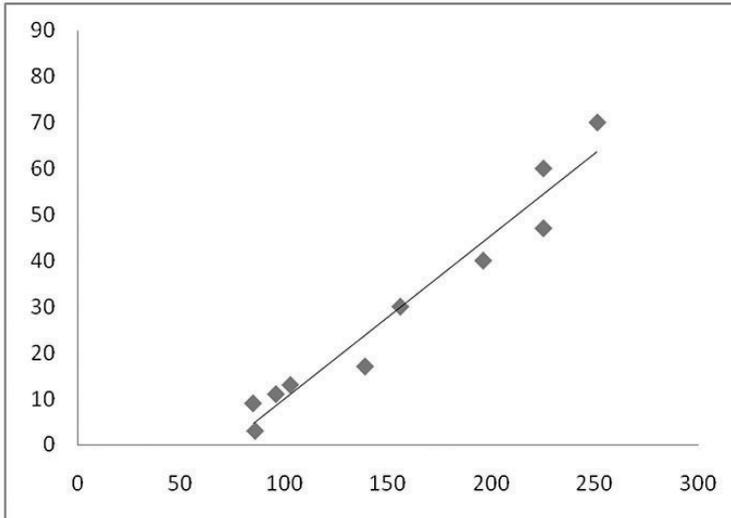


Figura 3.11: Gráfico de dispersão frequência de funcionamento x quantidade de defeitos com linha de tendência. Repare que, neste novo gráfico, apesar da linha de tendência ter a mesma inclinação (ou seja, o mesmo comportamento das variáveis), os pontos estão mais próximos dela, isto é, menos dispersos. Isso significa não somente que uma variável tem influência sobre a outra, mas, também, que tal influência é mais forte (a ponto de não permitir muitos “afastamentos” dos pontos). Em uma situação hipotética em que uma variável tivesse influência total sobre outra, a ponto de nada mais afetar seu comportamento, os pontos estariam todos sobre a reta.

De acordo com Christo (2017, p. 13), as duas variáveis representadas em um diagrama de dispersão podem ser:

- duas causas de um processo;
- uma causa e uma efeito de um processo;
- dois efeitos de um processo.

E podemos encontrar basicamente cinco possibilidades para elas:

1. Os pontos estão nitidamente alinhados sobre uma linha imaginária, inclinada “para cima”, o que significa que há uma forte vinculação entre as variáveis e que o aumento de uma leva ao aumento da outra e vice-versa. Neste caso, diz-se que há uma forte correlação positiva entre as variáveis.
2. É possível perceber uma inclinação “para cima” de uma linha imaginária, mas os pontos estão dispersos, sendo um pouco mais difícil identificar tal tendência. Em situações como esta, temos ainda uma correlação positiva entre as variáveis, mas tal correlação já não é forte.

3. Não é possível perceber qualquer relação entre as variáveis, com os pontos estando dispersos. Dizemos, neste caso, não haver correlação entre as variáveis, ou seja, uma não influencia a outra.
4. Ainda com os pontos dispersos, percebe-se uma inclinação de uma reta imaginária “para baixo”. Ou seja, o aumento de uma variável causa a diminuição das outras, mas a influência não é muito intensa: trata-se de uma correlação negativa fraca.
5. Quando a inclinação “para baixo” é nítida, com os pontos bem próximos à linha imaginária descendente, o efeito de uma variável sobre a outra é bastante acentuado e temos a denominada correlação negativa forte.

Você pode observar tais possibilidades na figura a seguir:

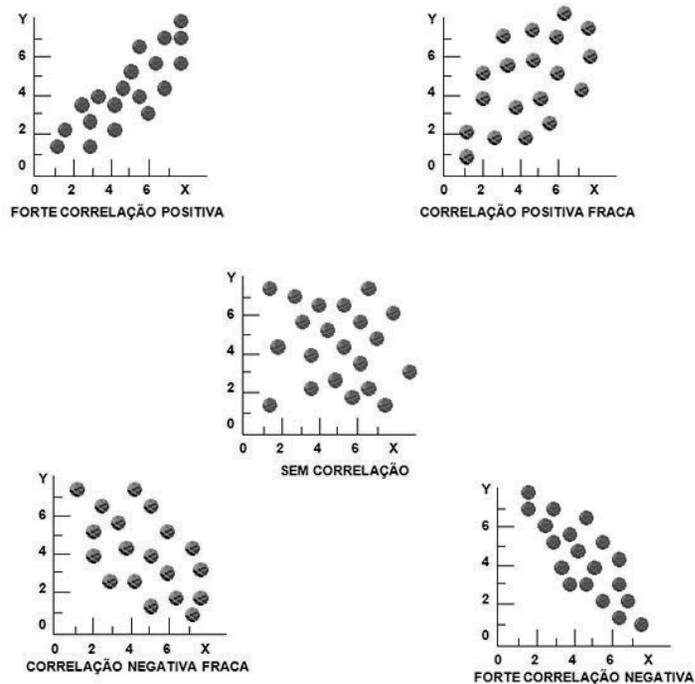


Figura 3.12: Exemplos de gráficos de dispersão. São mostrados exemplos em que a correlação entre as variáveis é positiva (quando uma aumenta, a outra também aumenta e quando uma diminui, a outra acompanha, diminuindo também), correlação negativa (quando o comportamento é inverso, isto é, quando uma aumenta, a outra diminui, e, também, sem correlação identificável, ou seja, quando não é possível inferir a existência de correlação entre as variáveis. Perceba, também, que as correlações, positivas ou negativas, podem ser fortes ou fracas (pontos mais ou menos dispersos).

Fonte: Adaptado de Santos (2009), Carpinetti (2012) e Ramos, Almeida e Araújo (2013).

Alguns cuidados devem ser, no entanto, tomados quando são traçados os diagramas de dispersão: Lozada (2017) indica a necessidade de serem utilizados ao menos 30 pontos, visto que, com poucos pontos, a visualização das relações entre as variáveis pode ficar comprometida. Santos (2009) alerta, também, quanto a ser feita uma estratificação adequada dos dados, visto que se forem de origens ou pertencerem a populações diferentes (por exemplo, componentes oriundos de duas máquinas distintas), a análise pode ficar comprometida. O autor chama a atenção, também, sobre possíveis erros, caso a escala adotada seja inadequada, o que nos levaria a analisar somente uma parte dos pontos, sendo necessário que haja conhecimento sobre o processo, para que seja feita uma boa análise dos diagramas.

Tal recomendação encontra sustentação, também, nas preocupações externadas por Christo (2017, p. 14) quanto à análise dos diagramas. Por exemplo, a possibilidade de existirem outras variáveis no processo que fazem com que “X e Y variem no mesmo sentido ou em sentidos contrários, embora X e Y possam não ser correlacionadas”. X e Y estariam sendo influenciadas por uma terceira variável. Tais variáveis, denominadas intercorrentes (não conhecidas), poderiam, assim, indicar uma falsa correlação, razão pela qual é preciso conhecer os processos para que possa ser feita uma análise crítica sobre eventuais achados do diagrama de dispersão. Nesse sentido, a autora, bem como Carpinetti (2012), recomenda que a presença de *outliers* (pontos discrepantes, isolados, totalmente afastados dos demais, como o mostrado na figura a seguir) seja analisada separadamente, para compreender se ocorreu alguma causa especial e, a partir daí, tomar-se uma decisão sobre eles, isto é, considerá-los no estudo ou não.

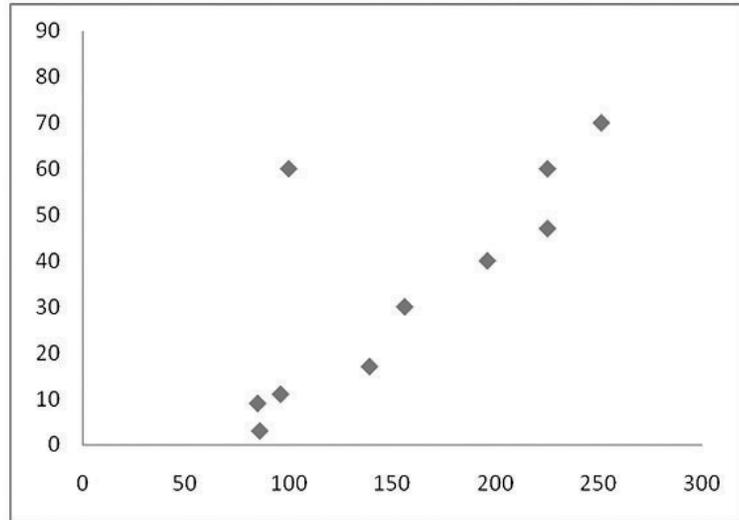


Figura 3.13: Gráfico de dispersão frequência de funcionamento x quantidade de defeitos com um ponto *outlier* (frequência de 100 Hz e 60 defeitos). Tais pontos devem ser analisados separadamente, para compreender a razão da discrepância para os demais e, se constatado que foi um erro na coleta ou que seu desvio teve uma causa específica, serem eliminados do conjunto de dados.

Outro aspecto relevante quanto ao diagrama de dispersão é o fato de que podemos mensurar o quão intensa é a relação entre as variáveis, ou seja, é possível calcular a correlação entre elas. Para tanto, utiliza-se o coeficiente de correlação linear, r , que pode ser calculado por (CARPINETTI, 2012, p. 91):

$$r = \frac{S_{xy}}{\sqrt{S_{xx} \times S_{yy}}}$$

onde:

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2$$

$$S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n y_i \right)^2$$

$$S_{xy} = (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - \frac{1}{n} \left(\sum_{i=1}^n x_i \right) \left(\sum_{i=1}^n y_i \right)$$

Sendo:

x_i e y_i os valores individuais (medidas) das variáveis que analisamos;

\bar{x} e \bar{y} os valores médios das medidas x e y ; e

n é a quantidade de medidas tomadas no estudo.

O cálculo de r leva invariavelmente a resultados entre -1 e $+1$. Os valores negativos indicam uma correlação negativa, enquanto valores positivos, uma correlação positiva. Se o cálculo de r resultar em zero, isso significa que não há qualquer relação entre as variáveis estudadas (correlação nula). Mas a análise dos sinais não indica se a correlação é forte ou fraca. Para isso é necessário analisar o valor do módulo de r : quando $|r| = 1$, há total correlação entre as variáveis, ou seja, os pontos estariam totalmente alinhados sobre a linha imaginária (linha de tendência). Podemos dizer que há 100% de correlação entre as variáveis.

Assim, os pontos de um diagrama em que $r = +1$ estariam sobre uma linha que “sobe”, ao passo que, em um diagrama em que $r = -1$, formariam uma linha que “desce”. Mas, e quando r for diferente de zero e diferente de $+1$ e -1 ? Isso significa que há alguma correlação entre as variáveis (ou seja, $r \neq 0$), mas ela não é total, plena. Ou seja, os pontos não estarão totalmente alinhados sobre uma reta imaginária: estarão muito dispersos (correlação fraca) ou relativamente próximos da linha (correlação forte). Moreira (2009) estabeleceu uma escala para interpretação dos valores do módulo de r :

Tabela 3.4: Escala para interpretação dos valores do módulo de r

$ r $	Correlação
0 a 0,2	Muito baixa
0,2 a 0,4	Baixa
0,4 a 0,6	Média
0,6 a 0,8	Alta
0,8 a 1,0	Muito alta

Coefficientes de correlação inferiores a 0,6 (em módulo) não são significativos e, como regra geral, não indicam trilhas de investigação a serem perseguidas para análise de problemas. Ainda que a análise visual

dos diagramas de dispersão seja fácil, bem como a análise do coeficiente de correlação, a elaboração dos gráficos, bem como o cálculo de r podem ser trabalhosos. A boa notícia é que o Excel torna isso muito simples, como você verá a seguir.

Utilizando o Excel

Vejamos, agora, como o Excel pode nos dar uma série de respostas rápidas quando utilizamos o diagrama de dispersão e o cálculo do coeficiente de correlação. Para isso, vamos tomar como exemplo uma empresa que suspeita que a temperatura ambiente influencie na quantidade de defeitos (cansaço dos trabalhadores, mal-estar, etc. poderiam ser as causas), mas, que suspeita, também, que empregados que não tenha tido treinamento suficiente possam estar tendo dificuldades com os processos e isso possa ser, igualmente, causa dos problemas. Tendo em vista estas suspeitas, a referida empresa realiza um levantamento da temperatura e de quantas horas de treinamento o operador tinha em cada período e de quantos defeitos ocorreram. Os resultados são apresentados a seguir:

Tabela 3.5: Dados coletados

Temperatura	Horas de treinamento	Defeitos
35	21	12
33	33	6
27	5	25
28	25	9
25	17	11
21	36	5
19	12	18
20	8	17
19	4	21
22	10	17
28	24	15
28	23	12
33	12	12
34	6	24
31	36	5

36	28	7
34	32	11
28	28	10
33	40	3

A cada período foi registrada a temperatura, o tempo de treinamento do operador e a quantidade de defeitos ocorridos. Você consegue tirar alguma conclusão sobre as informações constantes na tabela? Será que a temperatura e o tempo de treinamento influenciam na qualidade da empresa?



Seria importante que você abra o Excel e procurasse replicar o passo a passo que seguiremos agora, de forma a se familiarizar com os comandos e opções do programa.

Vamos, primeiramente, montar os gráficos: como queremos analisar a possível correlação entre a temperatura e a quantidade de defeitos e entre as horas de treinamento e a quantidade de defeitos, devemos criar um gráfico de dispersão para cada análise. Para o primeiro deles, selecione os dados de temperatura e os dados de defeitos, como mostrado na figura a seguir. Em seguida, insira um gráfico de dispersão.

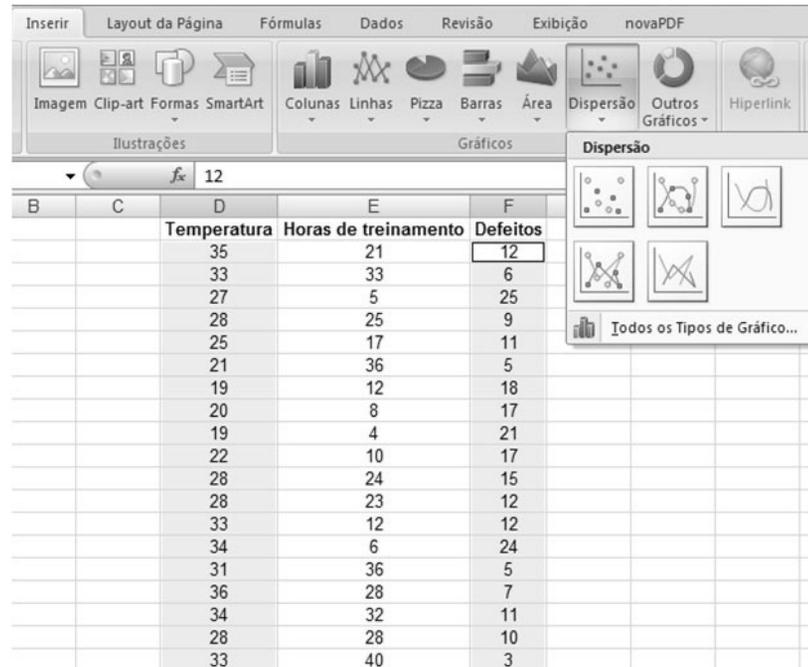


Figura 3.14: Uso do Excel para construir um diagrama de dispersão. Para seleccionar os dados nas duas colunas, selecione a primeira coluna, segure a tecla *Ctrl* e selecione a segunda coluna. Após inserir o gráfico, é possível editá-lo, incluindo legendas, etc.



Diferentes versões do Excel podem apresentar pequenas diferenças nos comandos.

Siga os mesmos passos para construir o segundo gráfico. Veja como eles ficam. Há alguma conclusão que você consegue tirar deles?

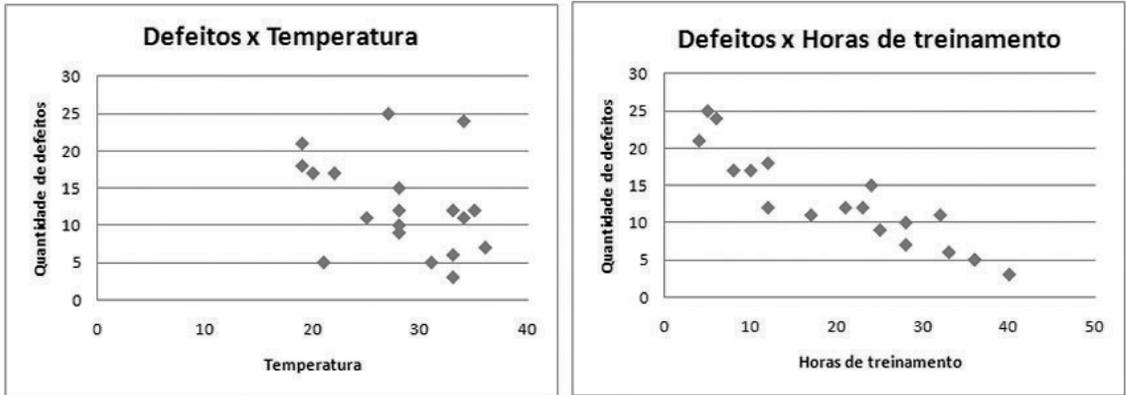


Figura 3.15: Gráficos construídos em Excel. Repare que no gráfico da esquerda não conseguimos encontrar um padrão claro, ao passo que o da direita apresenta uma clara relação entre as variáveis horas de treinamento e quantidade de defeitos.

É possível inserir uma linha de tendência nos gráficos, como mostrado na figura a seguir. Basta clicar sobre um dos pontos e, em seguida, clicar com o botão direito do mouse, para que você possa visualizar tal opção.

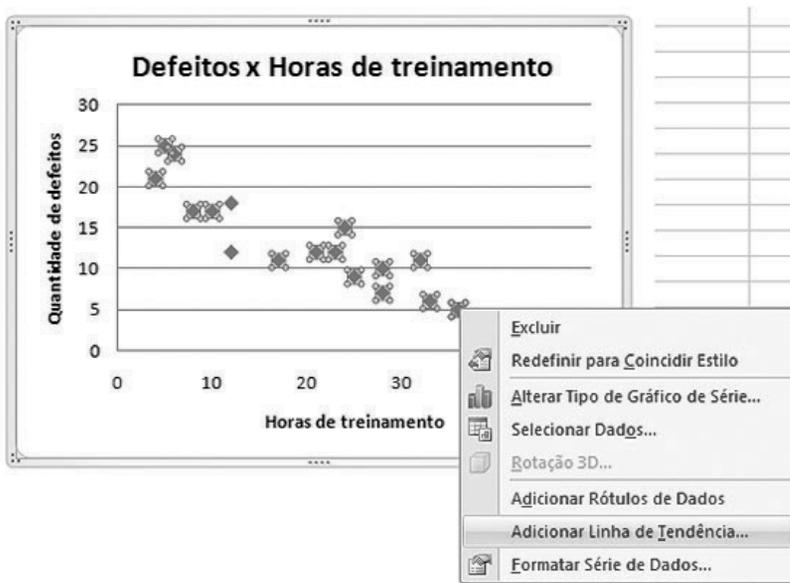


Figura 3.16: Inserir uma linha de tendência no gráfico. O Excel consegue identificar uma linha que represente uma tendência de alinhamentos dos pontos do gráfico: ao selecionar o comando “Adicionar Linhas de Tendência”, abre-se uma janela e você pode selecionar que tipo de linha de tendência: Exponencial, Linear, Logarítmica, Polinomial, Potência ou Média Móvel. Nos exemplos que estamos trabalhando, “Linear” é a mais adequada. Mas, você pode experimentar outras e verificar os resultados, ou seja, o quão bem a linha adicionada “se encaixa” nos pontos.

Atenção: mesmo que os pontos não apresentem um padrão claro, indicando que provavelmente não há correlação (como no caso do gráfico de temperatura x defeito, ainda assim, o Excel vai tentar adicionar uma linha de tendência). Isso não significa que o fato de haver tal linha presente, de fato, a existência de correlação significativa.

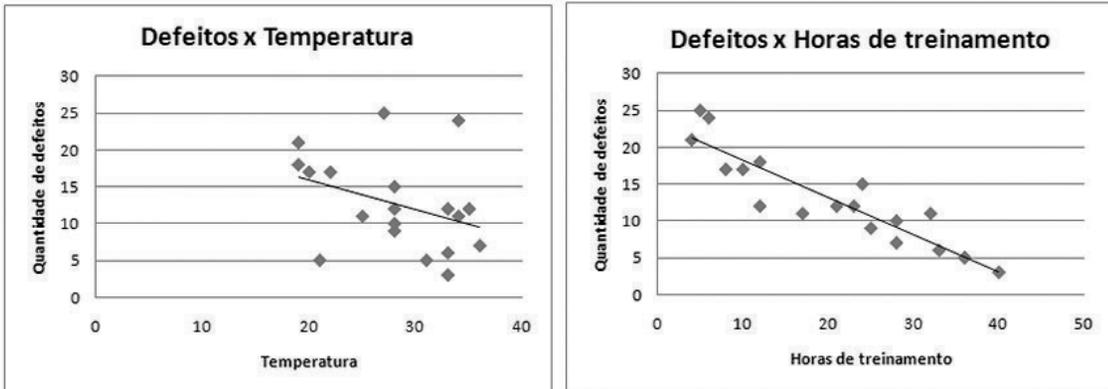


Figura 3.17: Gráficos construídos em Excel, em que foram adicionadas linhas de tendência. A adição da linha ocorre por mera inferência matemática do Excel. Isso não significa que haja correlação. Repare que, no gráfico da direita, os pontos estão bastante próximos da linha, o que nos indica uma alta correlação. Mas, e no da esquerda, podemos dizer a mesma coisa?

A observação dos gráficos já nos indica que parece não haver correlação entre a temperatura e a quantidade de defeitos. Por outro lado, parece haver uma forte correlação negativa entre as horas de treinamento e a quantidade de defeitos, ou seja, quanto mais tempo de treinamento o operador tem, menor a quantidade de defeitos gerados. Vamos verificar se nossa percepção é correta: para isso, vamos calcular o coeficiente de correlação entre as séries de dados. Para tanto, selecione uma célula para calcular o r e selecione “Fórmulas”, “Estatística” e busque a função de correlação, como mostrado na figura a seguir.

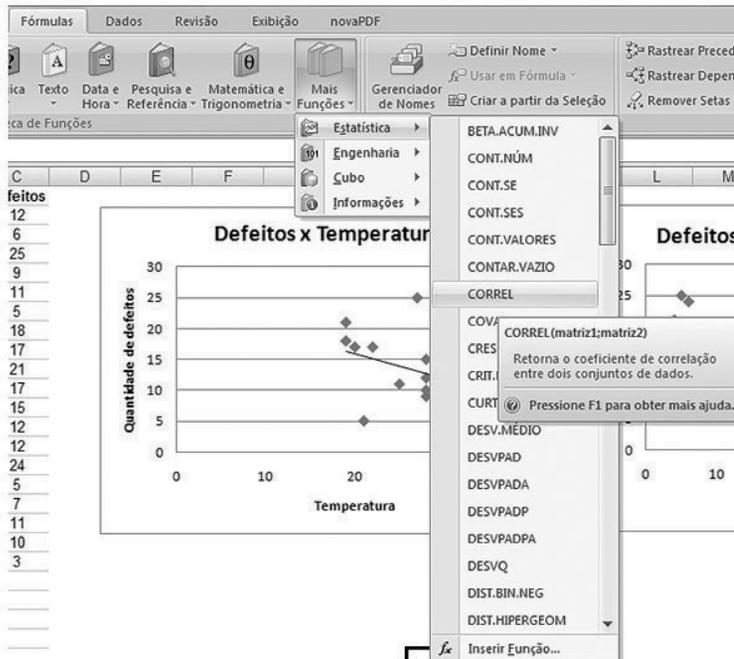


Figura 3.18: Função Estatística para cálculo do coeficiente de correlação. Com ela, calcula-se o r entre duas séries de dados, justamente os dados referentes às variáveis que queremos verificar se têm correlação.

Ao selecionar a função, é aberta uma janela em que você deve identificar duas matrizes (na realidade, as duas séries de dados das variáveis cujo coeficiente de correlação queremos que seja calculado. Uma vez selecionadas, basta clicar em OK e a célula selecionada mostrará o valor de r .

No nosso exemplo, encontramos para r um valor de $-0,36$ para a temperatura e a quantidade de defeitos, confirmando a nossa percepção ao observar o gráfico de que a temperatura não tem influência sobre a quantidade de defeitos. Desta forma, tal variável não deve fazer parte das áreas em que se deva desenvolver qualquer ação para melhoria da qualidade. Por outro lado, o de r para horas de treinamento e quantidade de defeitos foi de $-0,92$, um valor bastante alto (forte correlação negativa), indicando que investimentos em treinamentos deverão surtir forte impacto positivo na redução de defeitos e melhoria da qualidade da empresa.

Atividade

Atende aos objetivos 2 e 4

A empresa Zezinho's Technology vem enfrentando perdas substanciais nos últimos meses devido à queda nas vendas, ao aumento dos gastos com garantia, bem como aos processos movidos por alguns clientes por conta de defeitos encontrados nos produtos que ela produz. Um levantamento dos defeitos a cada dia, coletados em folhas de verificação, bem como as condições que se suspeita terem influência sobre os problemas é mostrado a seguir:

Dia	Operador (rodízio)	Temperatura (°C)	Tensão (V)	Umidade (%)	Defeitos
1	Carlos	25	129	78	51
2	Eduardo	24	118	44	2
3	Bernardo	22	119	59	21
4	Carlos	26	109	81	60
5	Eduardo	27	125	84	51
6	Alberto	27	127	72	60
7	Bernardo	29	135	59	35
8	Carlos	31	133	61	50
9	Carlos	30	112	77	55
10	Davi	31	114	44	7
11	Bernardo	29	110	78	42
12	Carlos	25	124	57	44
13	Carlos	24	123	78	55
14	Geraldo	28	132	41	4
15	Bernardo	29	122	53	34
16	Alberto	32	131	42	7
17	Geraldo	32	114	73	46
18	Alberto	34	115	60	44
19	Bernardo	36	109	69	42
20	Geraldo	31	124	55	15
21	Alberto	27	128	46	10
22	Davi	28	118	52	13

23	Carlos	26	125	80	84
24	Carlos	25	133	75	69
25	Bernardo	26	122	52	47
26	Geraldo	25	111	48	3
27	Davi	24	128	52	36
28	Alberto	22	125	48	9
29	Bernardo	24	129	62	11
30	Eduardo	23	127	62	25

Com base nos dados levantados, quais fatores parecem ser relevantes, merecendo atenção dos gestores para sofrerem algum tipo de ação, visando à melhoria da qualidade e redução dos defeitos? Dica: gráficos de tendência e de dispersão são bons instrumentos de análise, bem como o cálculo do coeficiente de correlação entre as variáveis estudadas.

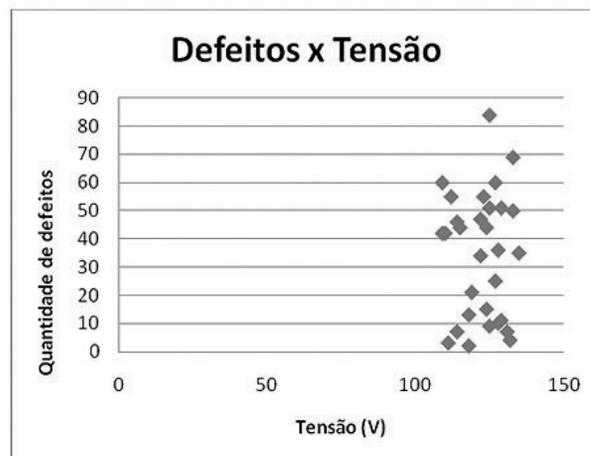
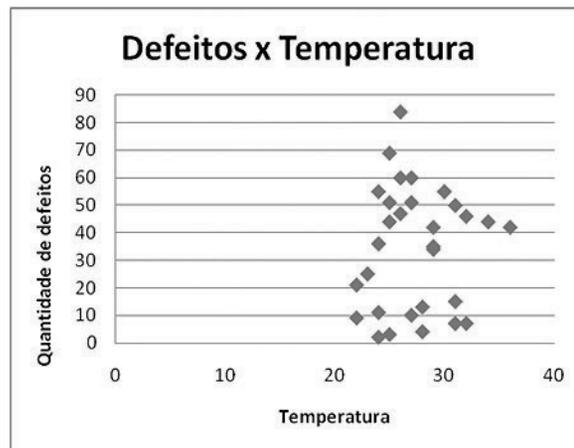
Resposta comentada

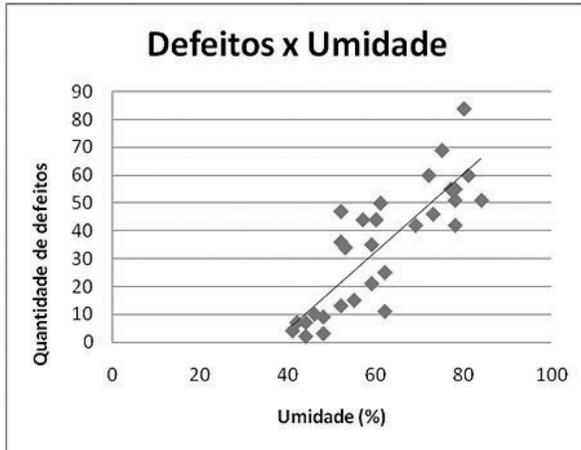
Primeiramente, vamos verificar se há alguma tendência nos defeitos, isto é, se eles estão aumentando ou diminuindo ao longo do tempo. Podemos fazer isso simplesmente colocando os dados da coluna de defeitos em um gráfico.



Como você pode perceber, não há nenhuma tendência específica de crescimento ou redução ao longo de tempo, nem qualquer zona com um pico nos defeitos. Podemos inferir, então, que deve haver alguma razão que leve aos aumentos e diminuições da quantidade de defeitos em cada dia.

Vamos prosseguir com a pesquisa: podemos utilizar diagramas de dispersão para avaliar se a temperatura, a tensão e a umidade relativa têm correlação com a quantidade de defeitos. Veja a seguir os gráficos:





Como você pode perceber, os diagramas de dispersão não indicam qualquer correlação entre a temperatura e a tensão com a quantidade de defeitos. No entanto, a umidade parece ter grande influência: uma correlação positiva entre a umidade relativa e a quantidade de defeitos (observe a linha de tendência que foi adicionada no gráfico).

Vamos nos certificar, calculando o coeficiente de correlação entre a temperatura, a tensão e a umidade com a quantidade de defeitos: como você já estudou, sabe que isso pode ser feito rapidamente pelo Excel. Seguem os resultados abaixo.

Fatores	r	Correlação
Temperatura x Defeitos	0,07	Muito baixa
Tensão x Defeitos	-0,01	Muito baixa
Umidade x Defeitos	0,84	Correlação positiva muito alta

Desta forma, o cálculo de r confirma o que os gráficos evidenciavam: o foco de atenção deve ser na umidade, ou seja, como há um evidente aumento na quantidade de defeitos quando há o aumento da umidade relativa, seria interessante que a empresa começasse a analisar a possibilidade de utilizar sistemas de controle de umidade para reduzir a quantidade de defeitos.

Mas, há ainda uma informação que não analisamos: os operadores. Será que eles influenciam na ocorrência de defeitos? Vamos aproveitar que a estratificação utilizada para construir as listas de verificação

registrou os nomes dos operadores e fazer tal análise. Para isso, vamos rearranjar a tabela com os resultados, como mostrado a seguir.

Dia	Operador	Defeitos	Média (defeitos/dia)
6	Alberto	60	26
18	Alberto	44	
21	Alberto	10	
28	Alberto	9	
16	Alberto	7	
25	Bernardo	47	33,1
11	Bernardo	42	
19	Bernardo	42	
7	Bernardo	35	
15	Bernardo	34	
3	Bernardo	21	
29	Bernardo	11	58,5
23	Carlos	84	
24	Carlos	69	
4	Carlos	60	
9	Carlos	55	
13	Carlos	55	
1	Carlos	51	
8	Carlos	50	
12	Carlos	44	18,7
27	Davi	36	
22	Davi	13	
10	Davi	7	26
5	Eduardo	51	
30	Eduardo	25	
2	Eduardo	2	17
17	Geraldo	46	
20	Geraldo	15	
14	Geraldo	4	
26	Geraldo	3	

Como você pode perceber, enquanto os outros operadores têm uma média entre 17 e 33,1 defeitos por dia, Carlos está muito acima disso, com uma média de 58,5 defeitos. Assim, além do controle da umidade, é importante que se entenda o que está levando Carlos a estar envolvido com tantos defeitos, muito mais que seus colegas: será que ele está em treinamento? Ou que precisa ser retreinado? Algum problema de falta de motivação? Algum problema pessoal que o esteja impedindo de se concentrar no trabalho? São possibilidades que precisam ser investigadas, para ajudar Carlos a desempenhar seu trabalho de forma adequada e aumentar o nível de qualidade da Zezinho's Technology.

Conclusão

O controle e a melhoria da qualidade passam por passos de processos estruturados e, em tais passos, é necessário lidarmos com informações diversas, para compreensão dos problemas e identificação de suas causas, de forma a podermos ser assertivos nas decisões sobre a qualidade e sua melhoria contínua. Nesse sentido, o uso de ferramentas da qualidade é altamente recomendável, pois elas nos guiam para um processo de análise estruturado.

A estratificação das informações mostra-se, assim, de grande valor, para que possamos “enxergar” os diversos fenômenos e permitir o uso de outras ferramentas. Os dados coletados por meio de folhas de verificação podem ser, então, processados e analisados: muitas ferramentas utilizam gráficos para suportar a análise (como, por exemplo, o diagrama de dispersão), tornando os fenômenos “visualizáveis”, o que facilita e torna mais robusto o processo de análise e solução de problemas.

Resumo

O controle e a melhoria da qualidade se desenvolvem por meio do uso de ferramentas específicas, as denominadas ferramentas da qualidade. São elas:

- Estratificação
- Folha de verificação
- Diagrama de dispersão
- Gráfico de Pareto

- Diagrama de causa e efeito
- Histograma
- Gráficos de controle

A estratificação diz respeito a separar as ocorrências (por exemplo, os defeitos) em classes (estratos), de tal forma que possam ser estudados. Por exemplo, pode haver a estratificação por tipo de defeitos, local de ocorrência, por operador, horário ou data, etc. A forma de estratificar vai definir a forma de coleta dos dados, os quais são registrados em listas de verificação. Tais listas consolidam os dados durante determinado período para que, posteriormente, os problemas possam ser analisados. Não há um formato único para tais instrumentos: depende do tipo de informação que queremos coletar e analisar, bem como da estratificação definida.

Uma das formas de se analisar os problemas é por meio dos diagramas de dispersão, que representam graficamente a existência de correlação entre variáveis (por exemplo, será que o aumento da temperatura ambiente faz com que haja mais defeitos de montagem em determinado produto?). As correlações, quando existem, podem ser positivas (se o valor de uma variável aumenta, a outra também aumenta e, se diminuir, a outra também diminui) ou negativas (as variáveis se deslocam em sentidos opostos). Além disso, tais correlações podem ser fortes (indicando grande influência de uma variável sobre a outra) ou fracas.

A correlação entre as variáveis pode, também, ser calculada pelo coeficiente de correlação: o valor varia entre zero (nenhuma correlação) a 1 (total correlação entre elas), podendo assumir valores positivos ou negativos (ou seja, entre -1 e +1), caso trate-se de correlações positivas ou negativas.

Leituras recomendadas

FABRIS, C. B. *Aplicação das ferramentas da qualidade em um processo produtivo em uma indústria de ração*. 74 p. Trabalho de Conclusão de Curso (Bacharelado Engenharia de Produção), Universidade Tecnológica Federal do Paraná. Medianeira, 2014. Disponível em: http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/4327/1/MD_COENP_TCC_2014_2_03.pdf. Acesso em: 16 ago. 2018.

HERAS, Iñaki; MARIMON, Frederic; CASADESUS, Martí. Impact of quality improvement tools on the performance of firms using different quality management systems. *Innovar*, Bogotá , v. 21, n. 42, p. 161-174, out. 2011. Disponível em: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-50512011000400014&lng=pt&nrm=iso. Acesso em: 16 ago. 2018.

OLIVEIRA, J. A. et al. Um estudo sobre a utilização de sistemas, programas e ferramentas da qualidade em empresas do interior de São Paulo. *Prod.*, São Paulo, v. 21, n. 4, p. 708-723, 2011. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-65132011000400014&lng=pt&nrm=iso. Acesso em: 16 ago. 2018.

TRIVELLATO, A. A. *Aplicação das sete ferramentas básicas da qualidade no ciclo PDCA para melhoria contínua: estudo de caso numa empresa de autopeças*. 72 p. Trabalho de Conclusão de Curso (Engenharia de Produção), Universidade de São Paulo, São Carlos, 2010. Disponível em: http://www.tcc.sc.usp.br/tce/disponiveis/18/180830/tce-19012011-162523/publico/Trivellato_Arthur_Antunes.pdf. Acesso em: 16 ago. 2018.

Informação sobre o próximo conteúdo

Na próxima aula, continuaremos os estudos das ferramentas para o controle da qualidade, trabalhando o gráfico de Pareto.

Referências

AMERICAN SOCIETY FOR QUALITY (ASQ). *Certified Quality Engineer*. Disponível em: https://p.widencdn.net/lnuqrw/40216_CQE_Cert_Insert. Acesso em: 16 ago. 2018.

CAMPOS, V. F. *TQC: controle da qualidade total (no estilo japonês)*. São Paulo: INDG, 2004.

CARPINETTI, L. C. R. *Gestão da qualidade: conceitos e técnicas*. 2. ed. São Paulo: Atlas, 2012.

CHRISTO, E. S. *Aula 3 – Ferramentas para o controle da qualidade*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 3), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=5>. Acesso em: 08 fev. 2019.

LOZADA, G. *Controle estatístico de processos*. Porto Alegre: SAGAH, 2017.

MOREIRA, D. A. *Administração da produção e operações*. 2. ed. São Paulo: Cengage Learning, 2008.

PEINADO, J.; GRAEML, A. R. *Administração da produção: operações industriais e de serviços*. Curitiba: UnicenP, 2007.

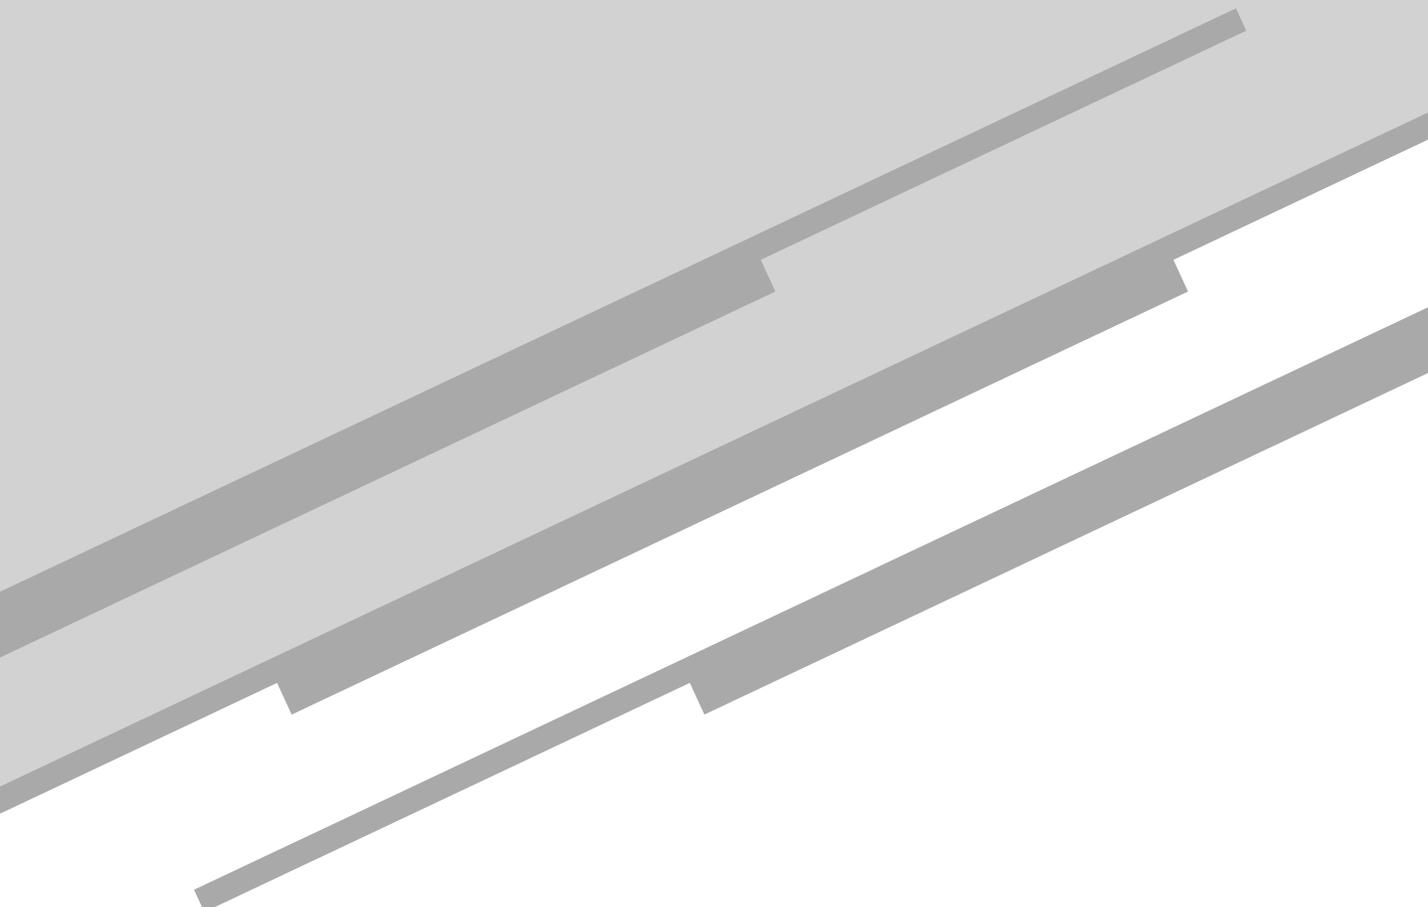
RAMOS, E. M. L. S.; ALMEIDA, S. S.; ARAÚJO, A. R. *Controle estatístico da qualidade*. Porto Alegre: Bookman, 2013.

SANTOS, J. A. N. *Análise e melhoria de processos*. Resende: UERJ, 2009.

SILVA, R. F. *Aplicação do FMEA no gerenciamento de riscos na qualidade do processo da indústria eletrônica*. 110f. Monografia (MBA Executivo em Gestão de Projetos). Campinas: Fundação Getúlio Vargas, 2018.

Aula 4

Ferramentas para o controle da
qualidade: gráfico de Pareto



Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. saber como utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. conhecer o diagrama (ou gráfico) de Pareto, que é uma das ferramentas mais utilizadas no controle da qualidade para definir o(s) problema(s) que mais prejudica(m) o processo.

Pré-requisitos

Ciclo PDCA, estratificação, folha de verificação e diagrama de Dispersão, conteúdos abordados nas aulas anteriores.

Introdução

O controle da qualidade exige um processo estruturado de trabalho, bem como o uso de ferramentas diversas. As ferramentas mais utilizadas ganham o nome de “ferramentas da qualidade” e se prestam a auxiliar a identificação e análise dos problemas. Dentre elas, se destaca o diagrama de Pareto, uma ferramenta com uma lógica muito simples, mas de grande potencial nos processos de manutenção e melhoria da qualidade.

O diagrama de Pareto permite identificar prioridades, isto é, o que é mais relevante sob determinada ótica. Por exemplo, pode nos auxiliar a selecionar quais problemas são mais impactantes para a empresa e, conseqüentemente, devem ser foco de atenção para conseguirmos saltos de desempenho da qualidade.

É isso que você estudará aqui: você verá o que é o diagrama de Pareto, como é construído e como é utilizado para o controle da qualidade. Bons estudos!

A busca pela manutenção e melhoria da qualidade exige das empresas um esforço para evitar a ocorrência de problemas e falhas e, também, a rápida e eficiente correção deles, quando ocorrem. No entanto, se há uma diversidade muito grande de problemas, tal tipo de ação pode ser difícil. Surge a pergunta: “Por onde começo?”

Assim, é importante haver uma forma de identificar os problemas, mas, principalmente, saber escolher onde atuar. Tal aspecto fora levantado por Daniel (1961), que identificou a dificuldade dos gestores em conseguir lidar com grande volume de informações, sendo necessário estabelecer um meio de identificar o que é mais relevante, ou seja, os “pouco vitais”.

Nesse sentido, Vilfredo Pareto (1848-1923), cientista político, sociólogo e economista italiano, que estudou engenharia na Università di Torino e atuou na Società delle Strade Ferrate Romana e na Società per l'Industria del Ferro (BIANCHI, 2016; VILFREDO PARETO, 2018), desenvolveu um estudo sobre a distribuição de renda, identificando um padrão que se repetia em diversas comunidades: 20% das pessoas detinham 80% da riqueza, enquanto as 80% demais viviam com somente 20% da riqueza.



Figura 4.1: Vilfredo Pareto. Sociólogo e economista italiano (ainda que tenha nascido em Paris, França, no período em que seus pais moravam nesse país), cujo nome de nascimento era Wilfried Fritz Pareto, desenvolveu inúmeros estudos na área da política, sociologia e economia, dentre eles, a Teoria das Elites, curva de indiferença e eficiência.

Fonte: <https://radiounifei.wordpress.com/2012/03/12/a-ciencia-economica-o-bem-estar-economico-e-social-e-as-ideias-de-vilfredo-pareto/>

Tal padrão de distribuição (isto é, o denominado 80/20) é encontrado em diversas outras áreas além da economia: 80% da receita sendo oriunda de 20% dos clientes; 80% dos custos de inventário são devidos a 20% dos itens em estoque; 80% dos atrasos de entregas têm como fonte 20% dos fornecedores, etc. (CORRÊA; CORRÊA, 2004).

Assim sendo, se identificarmos quem é responsável por 80% dos problemas de qualidade, não será surpresa se encontrarmos que somente 20% causam isso. Joseph Moses Juran (1904-2008), um dos “gurus da qualidade” (vide Aula 1) percebeu isso e propôs que o modelo de Pareto fosse utilizado para o controle da qualidade (CORRÊA; CORRÊA, 2004; LOZADA, 2017).

Ferramentas para o controle da qualidade

Como você viu na Aula 3, há sete ferramentas para o controle da qualidade:

- Estratificação;
- Folha de verificação;
- Diagrama de dispersão;
- Gráfico de Pareto;
- Diagrama de causa e efeito;
- Histograma;
- Gráficos de controle.

Cada uma delas tem um uso e uma função específica. Mas isso não significa que devam ser usadas isoladamente. Ao contrário, elas se complementam quando buscamos resolver problemas e aprimorar a qualidade nas organizações.

Como você viu na Aula 3, a estratificação nos permite classificar os dados em grupos, possibilitando estudar cada grupo separadamente e verificar se eles têm alguma característica específica, tendência, etc. Pode, portanto, nos auxiliar a identificar grupos de problemas e, como citado por Campos (2004), dividir um problema em estratos, ou seja, camadas de problemas diferentes, por exemplo, os 20% que causam 80% dos impactos negativos. Perceba como a estratificação viabiliza o uso do diagrama de Pareto.

Da mesma forma, como já visto na Aula 3, a folha de verificação, outra das ferramentas da qualidade, viabiliza a coleta dos dados estratificados, sendo necessária sua utilização para podermos construir o diagrama de Pareto. “O diagrama de Pareto é elaborado com base na folha de verificação ou outra fonte de coleta de dados, com o intuito de ajudar a dirigir a atenção e esforços para problemas importantes” (SANTOS, 2009, p. 32).

Construindo o diagrama de Pareto

Vamos construir um gráfico de Pareto, tomando por base o passo a passo estabelecido por Santos (2009) e Lozada (2017). Para isso, vamos

considerar uma situação fictícia de uma montadora de caminhões que mantém em estoque alguns componentes, como motor, pneus, etc. Preocupado com o custo deste material, o gerente de materiais pediu um levantamento de itens e seus valores, tendo encontrado as seguintes informações:

Tabela 4.1: Itens estocados, quantidades, valor unitário e valor total. O estoque de materiais é sempre uma preocupação das empresas, pois eles representam dinheiro investido e que está parado. Além disso, há o risco de deterioração, obsolescência, roubo, etc.

Item	Descrição	Custo unitário	Quantidade	Custo total
1	Pneus	R\$ 1.000,00	10	R\$ 10.000,00
2	Transmissão	R\$ 10.000,00	14	R\$ 140.000,00
3	Parafusos	R\$ 5,00	100	R\$ 500,00
4	Faróis	R\$ 500,00	10	R\$ 5.000,00
5	Volante	R\$ 130,00	20	R\$ 2.600,00
6	Chicote elétrico	R\$ 280,00	15	R\$ 4.200,00
7	Chassi	R\$ 22.000,00	15	R\$ 330.000,00
8	Cabine	R\$ 10.000,00	7	R\$ 70.000,00
9	Tanque	R\$ 800,00	8	R\$ 6.400,00
10	Motor	R\$ 38.000,00	12	R\$ 456.000,00
TOTAL				R\$ 1.024.700,00

Repare que há valores que se destacam: por exemplo, “motor”, com R\$ 456.000, e “chassis”, com R\$ R\$330.000. Mas identificar “valores maiores” não é suficiente para uma análise adequada, pois não sabemos até onde devemos continuar identificando tais valores: será que devemos considerar, também, o 3º maior valor (“transmissão”, R\$ 140.000)? E o 4º valor (“cabine”, R\$ 70.000), etc.? Até que ponto é relevante e adequado?

Como a preocupação do gerente está relacionada aos custos, o primeiro passo é reordenar as informações constantes no levantamento em ordem decrescente de valor. Ou seja, passaremos a ver primeiramente os valores mais altos, isto é, os que são motivo de maior preocupação, como pode ser visto na tabela a seguir:

Tabela 4.2: Itens ordenados pelo valor total

Item	Descrição	Custo unitário	Quantidade	Custo total
10	Motor	R\$ 38.000,00	12	R\$ 456.000,00
7	Chassi	R\$ 22.000,00	15	R\$ 330.000,00
2	Transmissão	R\$ 10.000,00	14	R\$ 140.000,00
8	Cabine	R\$ 10.000,00	7	R\$ 70.000,00
1	Pneus	R\$ 1.000,00	10	R\$ 10.000,00
9	Tanque	R\$ 800,00	8	R\$ 6.400,00
4	Faróis	R\$ 500,00	10	R\$ 5.000,00
6	Chicote elétrico	R\$ 280,00	15	R\$ 4.200,00
5	Volante	R\$ 130,00	20	R\$ 2.600,00
3	Parafusos	R\$ 5,00	100	R\$ 500,00
TOTAL				R\$ 1.024.700,00

Observe que a ordenação foi do maior para o menor valor, isto é, começando por “motor” e indo até “parafusos”. Isso é feito porque queremos identificar os itens mais relevantes, tomando por base o fator de estratificação adotado (no caso, o custo do inventário de materiais da fábrica).

Ainda que já tenhamos ordenado os valores e, conseqüentemente, consigamos identificar os itens de maior relevância quanto ao custo, a tabela não nos permite uma percepção de proporções, ou seja, quão maior um item é em relação aos demais. Para solucionar isso, o diagrama de Pareto utiliza como recurso a construção de um gráfico de barras, como mostrado na figura a seguir:

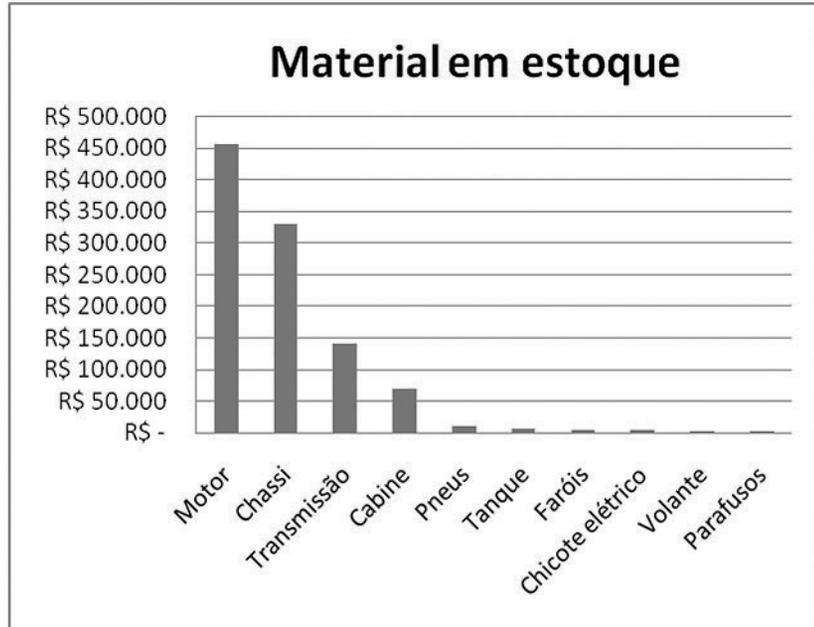


Figura 4.2: Gráfico mostrando em ordem decrescente os valores do material em estoque.

Repare que, se por um lado perdemos precisão nos detalhes (por exemplo, sabemos que “motores” têm um valor um pouco superior a R\$ 450.000,00, mas não temos como precisar o valor exato somente pelo gráfico), por outro lado, temos uma visão geral dos diversos itens e o quanto alguns deles são representativos.

Como outras ferramentas da qualidade (como o diagrama de dispersão), o digrama de Pareto utiliza a visualização como um instrumento para compreensão e análise dos problemas e dos diversos fenômenos. Mas tal visualização ainda não é suficiente para nos indicar a proporção 80/20 e, por isso, seguimos os demais passos previstos para a construção do diagrama de Pareto.

Para que possamos identificar tal proporção, precisamos calcular o percentual que cada item representa do todo. Para isso, dividimos o valor total de cada um dos itens pelo valor total dos itens (no nosso exemplo, o total é de R\$ 1.024.700,00, como pode ser visto nas **Tabelas 4.1 e 4.2**).

Tabela 4.3: Itens ordenados pelo valor total, com a indicação do percentual de cada um. Para tanto, foi dividido o valor total do item pelo valor total final. (Por exemplo, 456.000 divididos por 1.024.700 é igual a 0,445, ou 44,5%. Repare que o item “parafusos” mostra 0%: isso se deve ao valor ser muito baixo (0,0488%), e o valor foi arredondado.)

Item	Descrição	Custo unitário	Quantidade	Custo total	%
10	Motor	R\$ 38.000,00	12	R\$ 456.000,00	44,5%
7	Chassi	R\$ 22.000,00	15	R\$ 330.000,00	32,2%
2	Transmissão	R\$ 10.000,00	14	R\$ 140.000,00	13,7%
8	Cabine	R\$ 10.000,00	7	R\$ 70.000,00	6,8%
1	Pneus	R\$ 1.000,00	10	R\$ 10.000,00	1,0%
9	Tanque	R\$ 800,00	8	R\$ 6.400,00	0,6%
4	Faróis	R\$ 500,00	10	R\$ 5.000,00	0,5%
6	Chicote elétrico	R\$ 280,00	15	R\$ 4.200,00	0,4%
5	Volante	R\$ 130,00	20	R\$ 2.600,00	0,3%
3	Parafusos	R\$ 5,00	100	R\$ 500,00	0,0%
TOTAL				R\$ 1.024.700,00	100,0%

Tal ordenação e cálculo das porcentagens de cada item, no entanto, não nos permite inferir a regra 80/20, isto é, quais itens totalizariam aproximadamente 80% das ocorrências. Para tanto, é necessário que calculemos os percentuais acumulados: por exemplo, o motor sozinho representa 44,5%; já o motor + o chassi representam $44,5\% + 32,2\% = 76,7\%$, e assim sucessivamente, como você pode ver na tabela a seguir.

Tabela 4.4: Itens ordenados por valor total, com totalização cumulativa do percentual de cada um. Com a totalização cumulativa, é possível identificar os itens que são caracterizados como mais relevantes, de acordo com a regra 80/20.

Item	Descrição	Custo unitário	Quantidade	Custo total	%	Cum %
10	Motor	R\$ 38.000,00	12	R\$ 456.000,00	44,5%	44,5%
7	Chassi	R\$ 22.000,00	15	R\$ 330.000,00	32,2%	76,7%
2	Transmissão	R\$ 10.000,00	14	R\$ 140.000,00	13,7%	90,4%
8	Cabine	R\$ 10.000,00	7	R\$ 70.000,00	6,8%	97,2%
1	Pneus	R\$ 1.000,00	10	R\$ 10.000,00	1,0%	98,2%
9	Tanque	R\$ 800,00	8	R\$ 6.400,00	0,6%	98,8%
4	Faróis	R\$ 500,00	10	R\$ 5.000,00	0,5%	99,3%
6	Chicote elétrico	R\$ 280,00	15	R\$ 4.200,00	0,4%	99,7%
5	Volante	R\$ 130,00	20	R\$ 2.600,00	0,3%	100,0%
3	Parafusos	R\$ 5,00	100	R\$ 500,00	0,0%	100,0%
TOTAL				R\$ 1.024.700,00	100,0%	

A partir daí, temos todas as informações necessárias para montar o diagrama de Pareto, como mostrado na figura a seguir:

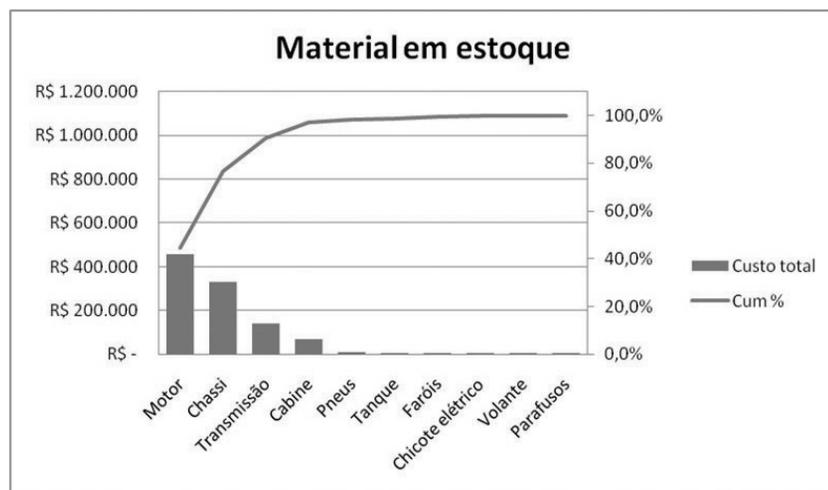


Figura 4.3: Diagrama de Pareto do custo do material em estoque. Reparem que é possível visualizar os poucos itens (“motor” e “chassis”) que são responsáveis por aproximadamente 80% do valor total do inventário.

E se tivéssemos elaborado a tabela e o diagrama de Pareto e não tivéssemos encontrado um total próximo a 80%? Isso pode acontecer, por exemplo, se as variáveis escolhidas para a aplicação da ferramenta não

apresentarem uma “concentração” de valores, isto é, se as frequências de distribuição forem próximas.

Vamos a um exemplo em que isso aconteceria: se a estratificação estabelecida no estudo (vide Aula 3) nos trouxesse cinco classes com aproximadamente 20% de distribuição cada. Nesse caso, alcançaríamos aproximadamente 80% das ocorrências somente quando considerássemos quatro das cinco classes identificadas, o que não nos traria qualquer benefício em termos de análise. Nesse caso, como indicado na Aula 3, a estratificação precisaria ser repensada.

A construção do gráfico utilizando o Excel pode seguir diferentes passos, dependendo da versão do editor da planilha. No Excel para Office 365, Excel para Office 365 para Mac, Excel 2016, Excel 2016 para Mac, Excel para iPad, Excel para iPhone, basta selecionar a coluna dos itens e dos valores (observando a **Tabela 4.1**, seriam as colunas “descrição” e “custo total”) e, em seguida, clicar em Inserir > Inserir Gráfico de Estatística e, em Histograma, selecionar Pareto (MICROSOFT, s.d.). O gráfico será automaticamente construído e, a partir daí é só uma questão de usar as guias Design e Formatar para personalizar a aparência do gráfico.

Versões mais antigas do Excel, que não contemplam a criação automática do diagrama de Pareto, demandam um pouco mais de trabalho: primeiramente, é necessário ordenar os itens, calcular os percentuais e a totalização cumulativa, como mostrado anteriormente (vide **Tabela 4.4**). Em seguida, devem ser selecionadas as colunas dos custos dos itens e do percentual cumulativo (tomando como exemplo a **Tabela 4.4**, seriam as colunas “custo total” e “cum %”).

Clica-se em Inserir e seleciona-se o gráfico de colunas, que é o ideal para comparar valores em diversas categorias. Ou seja, é exatamente o que queremos ao construir um diagrama de Pareto. No entanto, ao fazer tal seleção, não criamos, de fato, um diagrama de Pareto como o mostrado na **Figura 4.3**. Na verdade, ele ficará parecido com o mostrado a seguir:



Figura 4.4: Gráfico mostrando em ordem decrescente os valores do material em estoque. O gráfico pode ser formatado para ficar parecido com o mostrado na Figura 4.2, formatando título, eixos, etc.

No entanto, se foram selecionadas as colunas “custo total” e “cum %”, por que só vemos as barras referentes aos custos dos itens e não vemos os percentuais? A razão é que temos um gráfico único representando duas variáveis e as escalas delas são muito diferentes: por exemplo, o valor de “motores” (R\$456.00,00) e sua proporção percentual (44,5%) representam valores com ordens de grandeza muito diferentes. Isto é, 456.000 é mais de um milhão de vezes superior a 0,445 e, assim, quando colocamos os dois valores no mesmo gráfico, não conseguimos enxergar o menor valor.

Precisamos, então, ter escalas diferentes, para que possamos enxergar valores tão distintos em termos de ordem de grandeza. Além disso, como você deve ter percebido na **Figura 4.3**, a informação sobre percentual acumulado não é representada por barras, mas sim, por linha, de forma a facilitar a visualização do crescimento percentual que rege a regra 80/20. Desta forma, precisamos que o mesmo gráfico represente valores com grande diferença de escala e, também, com marcadores diferentes (coluna e linha).

Para tanto, é preciso clicar na barra do gráfico e, em seguida, clicar com o botão direito do mouse e selecionar “Formatar Série de Dados”, como mostrado na figura a seguir.



Figura 4.5: Preparando o gráfico de barras para convertê-lo em um diagrama de Pareto. Para isso, é necessário inserir novo eixo, com nova escala e substituir as barras por uma linha para mostrar o percentual acumulado.

É aberta uma janela e você deve selecionar “Eixo secundário” em “Plotar série no”. Isso fará com que os valores referentes ao percentual acumulado sejam reformatados em uma escala diferente, tendo por base um segundo eixo vertical, que aparece do lado direito do gráfico, como visto na figura a seguir.

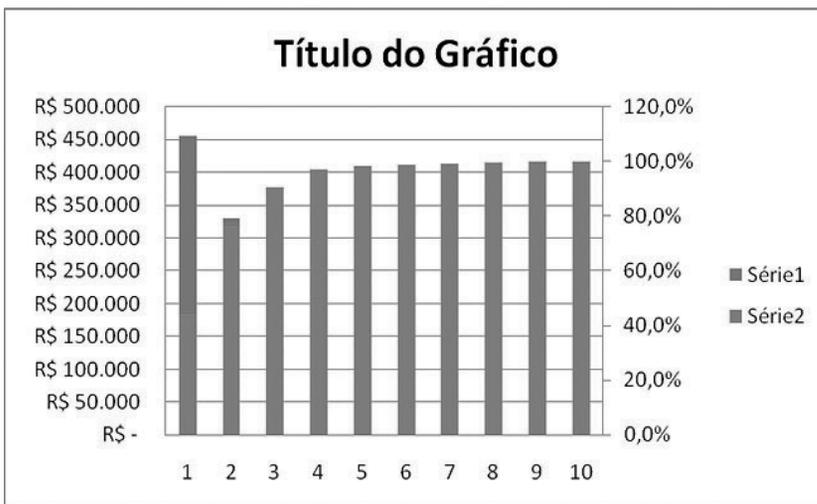


Figura 4.6: Preparando o gráfico de barras para convertê-lo em um diagrama de Pareto.

Como você pode perceber, as barras verticais referentes aos valores dos itens permanecem no gráfico, mas foram inseridas novas barras referentes ao percentual de valores acumulados, na escala do eixo da

direita. Mas o gráfico permanece confuso, pois há a sobreposição das barras dos valores e das porcentagens. Além disso, como já discutimos, a configuração usual do diagrama de Pareto é a de que a medição da porcentagem acumulada seja mostrada na forma de linha.

Para fazer tal modificação, é necessário mudar o tipo de gráfico, mas somente para tais valores: deve-se, então, selecionar novamente a série do percentual acumulado, clicar com o botão direito do mouse e selecionar “Alterar Tipo de Gráfico de Série”, como mostrado na figura a seguir:

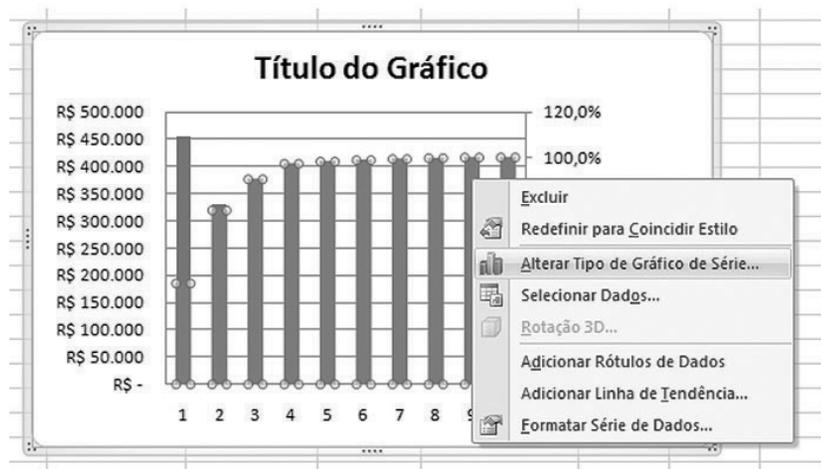


Figura 4.7: Preparando o gráfico de barras para convertê-lo em um diagrama de Pareto. Uma vez criado o eixo vertical secundário, que registra os valores do percentual acumulado, é preciso mudar a forma como o gráfico apresenta tais valores, passando de barra para linha.

Uma vez feita tal alteração, é uma questão de aplicar a formatação final no gráfico, inserindo e editando título, eixos e legendas, até que o gráfico fique semelhante ao mostrado na **Figura 4.3**. O diagrama de Pareto estará pronto! Isso significa que, uma vez coletados os dados, a construção de um diagrama de Pareto nos propiciará valiosa contribuição em termos de análise de dados e problemas? Não é bem assim: vamos discutir isso um pouco mais.

Utilizando o diagrama de Pareto

O diagrama de Pareto, ainda que seja uma ferramenta simples para construção e utilização, é bastante potente, mas depende fortemente de

uma boa estratificação dos dados (vide Aula 3). Isso acontece porque, se construirmos um diagrama de Pareto com dados cuja estratificação não evidencie qualquer tipo de acúmulo ou tendenciosidade, a regra 80/20 não funcionará e, conseqüentemente, não há como priorizar de forma adequada os esforços de análise dos problemas e suas causas-raiz, dificultando o estabelecimento de ações para manutenção e melhoria da qualidade.

Vamos tomar como exemplo os dados apresentados na atividade proposta na Aula 3, referente à empresa Zezinho's Technology e os defeitos registrados: a estratificação tomou por base os dias, o operador, a temperatura ambiente, a tensão de alimentação elétrica e a umidade relativa do ar. A partir dos dados coletados, são empregadas ferramentas que busquem identificar padrões.

Tabela 4.5: Lista de verificação com os dados da atividade proposta na Aula 3

Dia	Operador (rodízio)	Temperatura (°C)	Tensão (V)	Umidade (%)	Defeitos
1	Carlos	25	129	78	51
2	Eduardo	24	118	44	2
3	Bernardo	22	119	59	21
4	Carlos	26	109	81	60
5	Eduardo	27	125	84	51
6	Alberto	27	127	72	60
7	Bernardo	29	135	59	35
8	Carlos	31	133	61	50
9	Carlos	30	112	77	55
10	Davi	31	114	44	7
11	Bernardo	29	110	78	42
12	Carlos	25	124	57	44
13	Carlos	24	123	78	55
14	Geraldo	28	132	41	4
15	Bernardo	29	122	53	34
16	Alberto	32	131	42	7
17	Geraldo	32	114	73	46
18	Alberto	34	115	60	44
19	Bernardo	36	109	69	42

20	Geraldo	31	124	55	15
21	Alberto	27	128	46	10
22	Davi	28	118	52	13
23	Carlos	26	125	80	84
24	Carlos	25	133	75	69
25	Bernardo	26	122	52	47
26	Geraldo	25	111	48	3
27	Davi	24	128	52	36
28	Alberto	22	125	48	9
29	Bernardo	24	129	62	11
30	Eduardo	23	127	62	25

Vamos construir um diagrama de Pareto dos defeitos, tomando como base os dias. Para isso, os dados precisam ser ordenados, e os percentuais cumulativos, calculados, mas, não mostraremos todos esses passos (já explicados anteriormente), para que o texto não fique muito extenso. Somente os gráficos prontos serão mostrados.

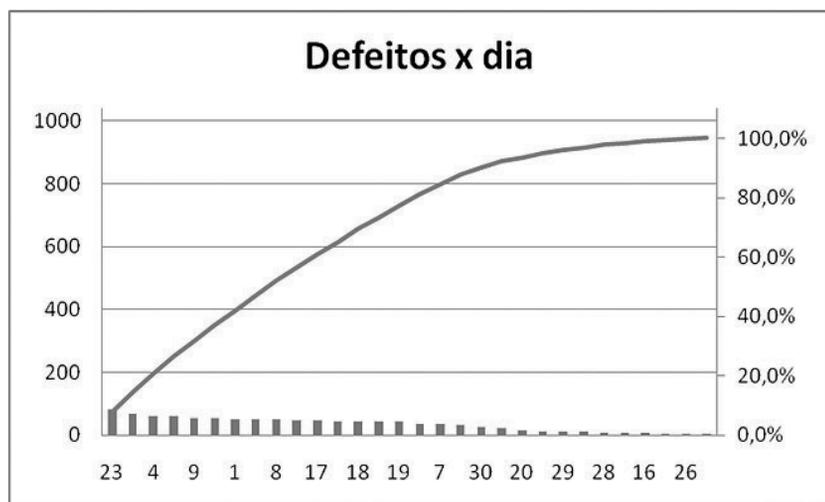


Figura 4.8: Diagrama de Pareto construído com os dados da atividade proposta na Aula 3.

Os defeitos foram estratificados por dia e ordenados de forma decrescente, iniciando no dia 23 (84 defeitos) e indo até o dia 2 (dois defeitos). No entanto, como você pode perceber, não há uma concentração

dos defeitos em poucos dias. Ao contrário, é possível perceber que as colunas mostram uma variação bem pequena e que a linha do percentual acumulado sobe lentamente, não caracterizando a regra 80/20 (compare, por exemplo, com o diagrama na **Figura 4.3**).

Como o diagrama de Pareto elaborado com base nos dias em que os defeitos ocorreram não nos mostrou qualquer aspecto relevante, consequentemente, a variável “dia” não merece ser explorada na investigação do problema. Vamos verificar, então, se conseguimos identificar alguma característica relevante dos defeitos quando relacionados à temperatura. Para isso, vamos construir o diagrama de Pareto tomando por base tal estratificação, mas vamos utilizar a quantidade média de defeitos ocorrida nos dias com a mesma temperatura. Isso é necessário para que a ocorrência de diversos dias com a mesma temperatura não fosse interpretada erroneamente com sendo uma temperatura que causasse muitos defeitos, como você pode ver na tabela a seguir:

Figura 4.6: Estratificação dos defeitos por temperatura.

Temperatura (°C)	Defeitos	Dias
36	42	1
34	44	1
32	53	2
31	72	3
30	55	1
29	111	3
28	17	2
27	121	3
26	191	3
25	167	4
24	104	4
23	25	1
22	30	2
Total	1032	30

Repare, por exemplo, a quantidade de defeitos com as temperaturas de 29 e 22 graus: há uma quantidade significativa de defeitos, porém isso pode ser em função da quantidade de dias que foram somados para tais

temperaturas (respectivamente, três e quatro). O diagrama de Pareto pode, então, ser construído, tomando por base a quantidade média de defeitos dos dias com a mesma temperatura, como pode ser visto na figura a seguir:

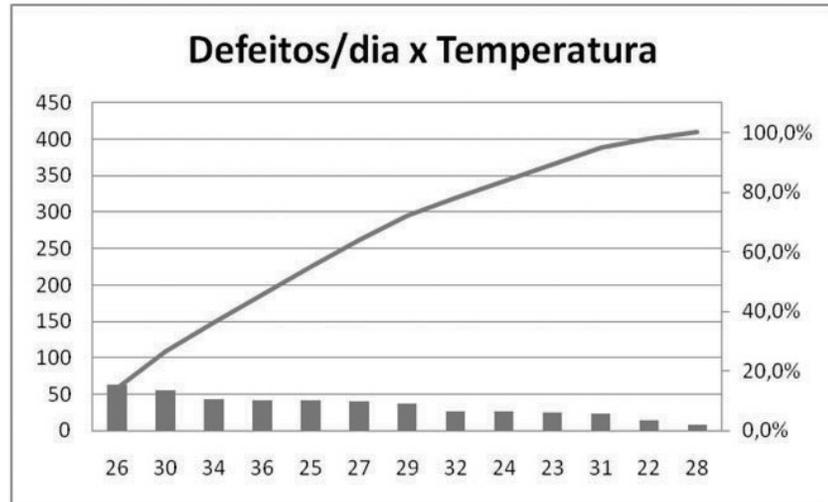


Figura 4.9: Diagrama de Pareto construído com os dados da atividade proposta na Aula 3.

Os defeitos foram estratificados por temperatura, considerando a quantidade média de defeitos por dia (pois há mais de um dia com a mesma temperatura). Da mesma forma que no caso dos defeitos estratificados por dia, não há uma concentração dos defeitos em determinadas temperaturas, o que pode ser percebido pela pequena variação na altura das colunas (defeitos por dia) e pela ascensão relativamente suave e contínua da linha que indica o percentual acumulado de defeitos, o que reforça o cenário de não haver uma concentração de defeitos por temperatura. Desenvolvendo a mesma análise para a tensão da rede, construímos o seguinte diagrama de Pareto:



Figura 4.10: Diagrama de Pareto construído com os dados da atividade proposta na Aula 3.

Os defeitos foram estratificados por tensão (em Volts), considerando a quantidade média de defeitos por dia (pois há mais de um dia com a mesma tensão medida). Repare que, novamente, não há uma concentração dos defeitos para determinados valores de tensão, indicando não ser um fator de influência sobre os defeitos. Já que a tensão não parece ser um fator de influência sobre os defeitos, vamos em frente: vamos fazer a mesma análise sobre a umidade relativa do ar. O diagrama de Pareto construindo com base em tal fator pode ser visto na figura a seguir:

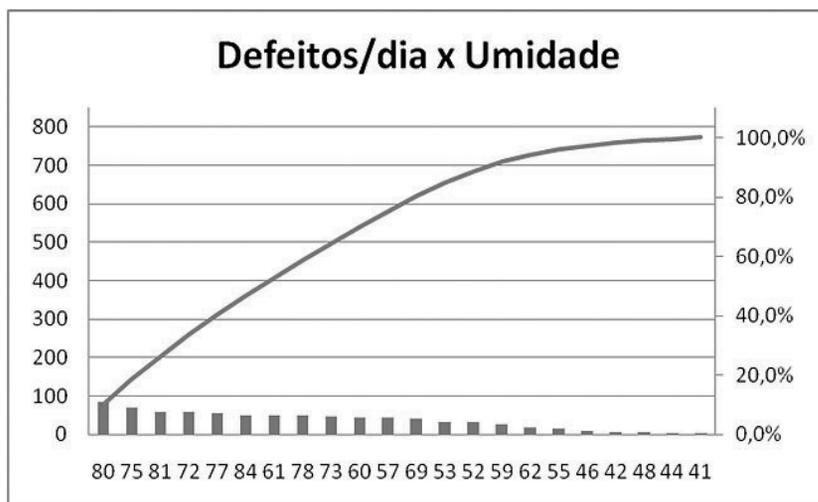


Figura 4.11: Diagrama de Pareto construído com os dados da atividade proposta na Aula 3.

Os defeitos foram estratificados com base na umidade relativa do ar no dia em que ocorreram, considerando a quantidade média de defeitos por dia (pois há mais de um dia com o mesmo valor de umidade). Repare que não há uma concentração dos defeitos para determinados valores de umidade. Mas tal resultado parece contradizer os resultados do diagrama de dispersão (que é replicado a seguir) e o cálculo do coeficiente de correlação entre a umidade e a quantidade de defeitos (vide Aula 3).

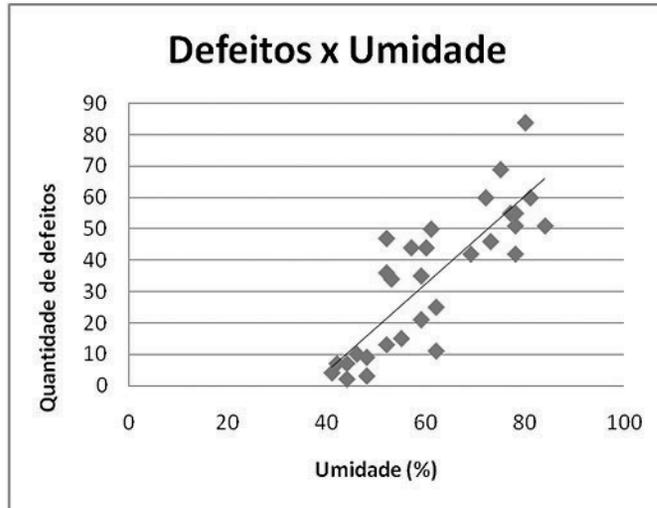


Figura 4.12: Diagrama de dispersão entre a umidade relativa do ar e a quantidade de defeitos, de acordo com os dados da atividade proposta na Aula 3.

Como você pode perceber, há uma correlação positiva entre tais variáveis: quanto maior a umidade, maior a quantidade de defeitos. A correlação evidenciada no gráfico de dispersão é confirmada no cálculo do coeficiente de correlação entre tais variáveis, que foi considerada muito alta.

Tabela 4.7: Coeficiente de variação entre a quantidade de defeitos e outras variáveis (temperatura, tensão e umidade).

Fatores	r	Correlação
Temperatura x Defeitos	0,07	Muito baixa
Tensão x Defeitos	-0,01	Muito baixa
Umidade x Defeitos	0,84	Correlação positiva muito alta

Como você pode perceber, a correlação entre a umidade e a quantidade de defeitos é muito alta e positiva. Ou seja, o aumento da umidade faz com que haja aumento na quantidade de defeitos. A explicação para essa aparente contradição é que há de fato tal correlação, ou seja, o aumento da umidade relativa do ar está associado à maior incidência de defeitos, como mostrado no gráfico de dispersão e confirmado pelo cálculo do coeficiente de correlação entre tais variáveis.

Entretanto, isso não significa que haja uma concentração de valores de umidade mais alta ou mais baixa. Repare como isso pode ser percebido no próprio gráfico de dispersão: as medidas de umidade estão distribuídas quase que uniformemente entre 40% e 85% (na verdade, se você verificar a **Tabela 4.5**, a umidade mínima foi de 41% e a máxima foi de 85%). Veja, na figura a seguir, como a distribuição das medidas de umidade relativa, ainda que não sejam perfeitamente contínuas, não mostra acúmulos significativos.



Figura 4.13: Distribuição dos valores de umidade relativa do ar.

Como você pode perceber, não há continuidade nos valores. Por exemplo, há “vazios” entre 49 e 52% e entre 63 e 68%. Mas não percebemos nenhuma concentração significativa de medidas, o que explica a razão de o diagrama de Pareto construído não ter revelado a proporção 80/20.

Desdobramento do diagrama de Pareto

Uma dúvida que pode surgir diz respeito às situações de grande complexidade, com inúmeros desdobramentos de ocorrências e problemas, usualmente de naturezas e contextos diferentes. Como o diagrama de Pareto pode nos auxiliar em situações como essas?

Christo (2017) sugere que, em contextos mais complexos, com grande diversidade de potenciais problemas, que haja um uso hierarquizado do diagrama de Pareto. Por exemplo, ao analisar os defeitos em uma linha de produção de automóveis, poderia ser desenvolvido um diagrama sobre o que poderia ser denominado “categorias prioritárias” e, a partir daí, desdobrá-las em novas análises, por meio de novos diagramas de Pareto, como mostrado a seguir.

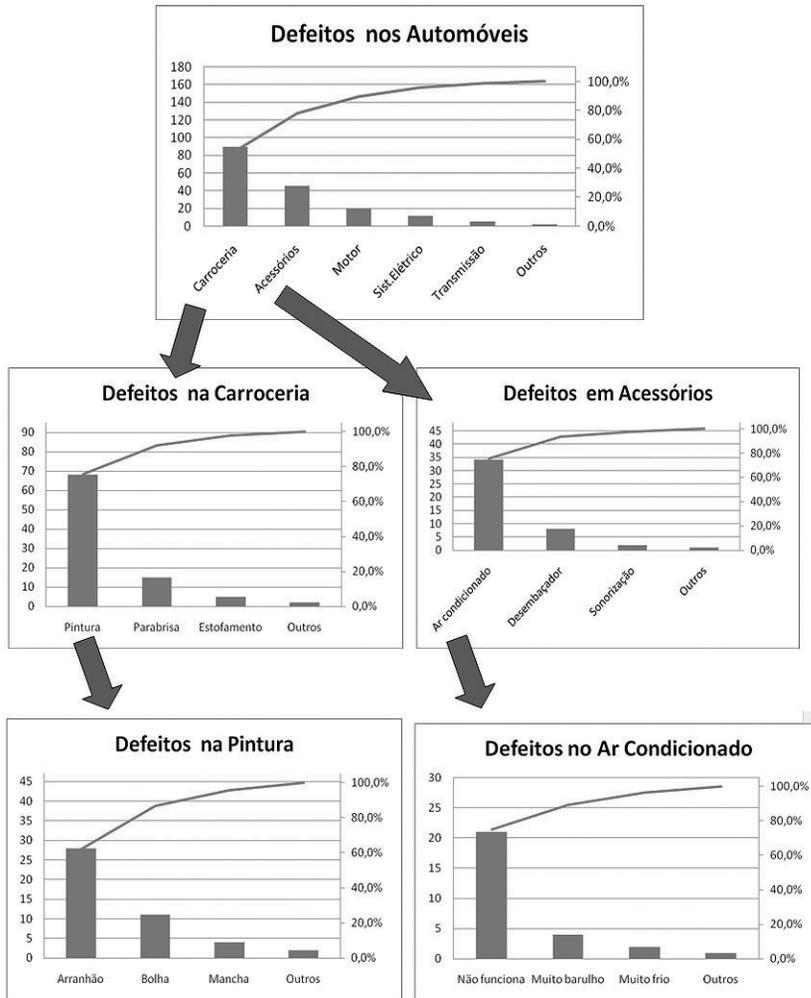


Figura 4.14: Desdobramentos do diagrama de Pareto. No problema de defeitos em automóveis, foram identificadas as categorias prioritárias do primeiro gráfico, e os problemas foram desdobrados em subcategorias para serem analisados por meio de novos gráficos.

Fonte: Adaptado de Christo (2017).

Uma forma expandida de utilização do diagrama de Pareto ocorre na área de gerenciamento de estoques, inventário e materiais em geral. Na denominada curva ABC, além da regra 80/20, são identificadas três regiões do diagrama, com base em valores e custos. Os materiais são classificados de acordo com tais categorias, denominadas A, B e C, em que aproximadamente 20% dos itens seriam responsáveis por 80% dos custos totais de inventário ou de vendas (os itens “classe A”: poucos itens e elevada importância); aproximadamente 30% dos itens seriam responsáveis por 15% do valor total (os itens “classe B”, de média importância) e os 50% restantes seriam responsáveis por meros 5% do valor (os itens “classe C”, os muitos triviais) (BALLOU, 2001; CORRÊA; CORRÊA, 2004).

A lógica construtiva da curva ABC é exatamente a mesma do diagrama de Pareto, exceto pelo fato de que, ao invés da separação 80/20, há também a 15/30 (referente aos itens B), criando as três regiões anteriormente citadas e que podem ser vistas na figura a seguir.



Figura 4.15: Curva ABC. Gráfico elaborado a partir das informações referentes aos materiais estocados no almoxarifado de um centro de pesquisa federal, que desenvolve estudos na área de saúde, contendo 526 itens no estoque, os quais foram classificados por meio da curva ABC, utilizando a quantidade de movimentações de cada um durante o ano.

Fonte: Vago et al. (2013).

Importante destacar que, ainda que o diagrama de Pareto seja intimamente reconhecido pela sua forma gráfica, isto é, pela caracterização da regra 80/20, em termos práticos, não há a necessidade de desenhar o gráfico para executar análises diversas: por exemplo, se explorarmos a situação dos defeitos na linha de produção de automóveis (vide **Figura**

4.14), poderíamos estabelecer os problemas e áreas prioritárias, mesmo que os gráficos não tivessem sido desenvolvidos. Bastaria analisar as proporções percentuais acumuladas dos problemas, como mostrado a seguir.

Tabela 4.8: Defeitos nos automóveis.

Área	Quantidade	Total	Cum %
Carroceria	90	90	52,0%
Acessórios	45	135	78,0%
Motor	20	155	89,6%
Sist. Elétrico	11	166	96,0%
Transmissão	5	171	98,8%
Outros	2	173	100,0%

Repare que, como os itens (as áreas de defeito) estão ordenados por quantidade de defeitos (ordem decrescente) e como foram calculados os percentuais cumulativos. É fácil identificar que as áreas “carroceria” e “acessórios” são responsáveis por aproximadamente 80% de todos os problemas. Ou seja, a regra 80/20 é identificada mesmo que o gráfico não seja desenhado.

Atividade

Atende aos objetivos 1 e 2

A empresa Zezinho's Technology vem enfrentando perdas substanciais nos últimos meses devido à queda nas vendas, ao aumento dos gastos com garantia, bem como devido aos processos movidos por alguns clientes, por conta de defeitos encontrados nos produtos que ela produz. A seguir, é mostrado um levantamento dos defeitos a cada dia, coletados em folhas de verificação, bem como as condições que se suspeita terem influência sobre os problemas.

Dia	Operador (rodízio)	Máquina	Defeitos
1	Carlos	1	51
2	Eduardo	2	2
3	Bernardo	3	60
4	Carlos	3	60
5	Eduardo	1	17
6	Alberto	3	31
7	Bernardo	3	69
8	Carlos	1	77
9	Carlos	2	55
10	Davi	3	7
11	Bernardo	2	72
12	Carlos	2	64
13	Carlos	3	55
14	Geraldo	1	4
15	Bernardo	3	34
16	Alberto	1	7
17	Geraldo	3	13
18	Alberto	3	14
19	Bernardo	1	42
20	Geraldo	2	7
21	Alberto	1	10
22	Davi	2	4
23	Carlos	3	84
24	Carlos	2	69
25	Bernardo	1	47
26	Geraldo	2	3
27	Davi	2	2
28	Alberto	3	9
29	Bernardo	3	11
30	Eduardo	3	5

Com base nos dados levantados, quais fatores parecem ser relevantes, merecendo atenção dos gestores para sofrerem algum tipo de ação, visando à melhoria da qualidade e à redução dos defeitos?

Resposta comentada

Precisamos verificar se há um acúmulo de defeitos em algum (ou em mais de um) dos operadores e fazer a mesma coisa para as máquinas. Como a quantidade de dias trabalhados pelos operadores não é a mesma, nem as máquinas são utilizadas igualmente, vamos calcular a quantidade média de defeitos por dia trabalhado por cada operador e em cada máquina. As tabulações são mostradas a seguir.

Primeiramente, vamos verificar se há alguma tendência nos defeitos, isto é, se eles estão aumentando ou diminuindo ao longo do tempo. Podemos fazer isso simplesmente colocando os dados da coluna de defeitos em um gráfico.

Operador (rodízio)	Média (defeitos/dia)
Alberto	14,2
Bernardo	47,9
Carlos	64,4
Davi	4,3
Eduardo	8
Geraldo	6,8

Máquina	Média (defeitos/dia)
1	31,9
2	30,9
3	34,8

Em seguida, elaboramos os diagramas de Pareto para as variáveis “operador” e “máquina”, os quais são mostrados a seguir.

Como você pode perceber, há diferença significativa na quantidade média de defeitos por dia entre os operadores: Carlos e Bernardo precisariam ser retreinados. Já quanto às máquinas, não há diferença significativa entre elas, não sendo causas geradoras de defeitos.

Conclusão

O diagrama de Pareto é uma das ferramentas da qualidade, tendo como principal uso a possibilidade de priorizar itens a serem analisados (por exemplo, quantidade de defeitos). Para isso, o diagrama depende da utilização de outras ferramentas, como a estratificação e a lista de verificação.

O diagrama de Pareto não gera soluções para os problemas, mas pode auxiliar no processo de investigação de causas (identificar as causas mais frequentes dos problemas), sendo de fácil utilização e tendo grande potencial na manutenção e melhoria da qualidade.

Resumo

Para o controle e a melhoria da qualidade, é comum a utilização de ferramentas, quais sejam:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de pareto;
- diagrama de causa e efeito;
- histograma;
- gráficos de controle.

O diagrama de Pareto se presta a estabelecer prioridades em um conjunto de dados. Por exemplo, quantidade de reclamações, defeitos, custo, etc. Ele se baseia na denominada regra 80/20, na qual é usual que 20% dos itens respondam por 80% dos eventos (por exemplo, 80%

das reclamações ou dos defeitos). Assim, é possível identificar os itens (também chamados “pouco vitais”) que devem ser escolhidos na análise e investigação dos problemas, priorizando as ações sobre estes.

Para identificação de tais itens, o diagrama de Pareto se inicia com a construção de uma tabela, na qual os itens são listados em ordem decrescente de eventos (defeitos, falhas, etc.). A partir daí, calcula-se a proporção de tais itens, isto é, o percentual que cada um deles representa do total de eventos. Os percentuais são, então, somados cumulativamente, ou seja, o primeiro item (o que apresenta a maior quantidade de problemas) tem seu percentual calculado. A seguir, soma-se tal percentual com o percentual do segundo item.

Feito isso, soma-se a esse percentual, o percentual do terceiro item, e assim sucessivamente, de tal forma que se identifique o percentual acumulado de cada item, até o último deles, totalizando os 100%. Tal tabulação permite identificar quais são os itens que totalizam aproximadamente 80% dos eventos, sendo estes selecionados como de ação prioritária para manutenção e melhoria da qualidade.

Leituras recomendadas

GALIAZI, D. R.; SANTOS, E. A. A Eficiência das ferramentas de qualidade no suporte ao gerenciamento de projetos. In: IV SIMPÓSIO INTERNACIONAL DE PROJETOS, INOVAÇÃO E SUSTENTABILIDADE – SINGEP. São Paulo, 8-10 nov. 2015. *Anais...* Disponível em: <https://singep.org.br/4singep/resultado/104.pdf>. Acesso em: 27 ago. 2018.

MAGRI, J. M. *Aplicação do método QFD no setor de serviços: estudo de caso em um restaurante 2009*. 43 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Produção) – Universidade Federal de Juiz de Fora, Juiz de Fora, 2009. Disponível em: http://www.ufjf.br/ep/files/2014/07/2009_1_Juliana.pdf. Acesso em: 7 set. 2018.

SANTOS, S. R.; MACIEL, A. J. S. Proposta metodológica utilizando ferramentas de qualidade na avaliação do processo de pulverização. *Eng. Agríc.*, Jaboticabal, v. 26, n. 2, p. 627-636, maio/ago. 2006. Disponível em: <http://repositorio.unicamp.br/bitstream/REPOSIP/202585/1/S0100-69162006000200033.pdf>. Acesso em: 7 set. 2018.

Informação sobre a próxima aula

Na próxima aula, continuaremos os estudos das ferramentas para o controle da qualidade, tratando do diagrama de causa e efeito e do histograma.

Referências

BALLOU, R. H. *Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial*. 4. ed. Porto Alegre: Bookman, 2001.

BIANCHI, A. Pareto, Mosca e a metodologia de uma nova ciência política. *Rev. Bras. Ciênc. Polít.*, Brasília, n. 19, p. 167-197, Abr. 2016. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-33522016000100167&lng=en&nrm=iso. Acesso em: 27 ago. 2018.

CHRISTO, E. S. *Aula 4 – Ferramentas para o controle da qualidade*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 4), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=6>. Acesso em: 8 fev. 2019.

CORRÊS, H. L.; CORRÊA, C. A. *Administração de produção e operações*. Manufatura e serviços: uma abordagem estratégica. São Paulo: Atlas, 2004.

DANIEL, D. Management Information Crisis. *Harvard Business Review*, Sep-Oct, 1961, p.111-125.

VILFREDO PARETO. Italian economist and sociologist. *Encyclopædia Britannica*, 15 aug. 2018. Disponível em: <https://www.britannica.com/biography/Vilfredo-Pareto>. Acesso em: 27 ago. 2018.

LOZADA, G. *Controle estatístico de processos*. Porto Alegre: SAGAH, 2017.

MICROSOFT. *Criar um gráfico Pareto*. Disponível em: <https://support.office.com/pt-br/article/criar-um-gr%C3%A1fico-pareto-a1512496-6dba-4743-9ab1-df5012972856>. Acesso em: 2 set. 2018.

SANTOS, J. A. N. *Análise e melhoria de processos*. Resende: UERJ, 2009.

VAGO, F. R. M.; SOUSA, C. V.; MELO, J. M. C.; LARA, J. E.; FAGUNDES, A. F. A., SAMAPIO, D. O. A importância do gerenciamento de estoque por meio da ferramenta curva ABC. *Sociais e Humanas*, Santa Maria, v. 26, n. 03, set/dez 2013, p. 638-655. Disponível em: <https://periodicos.ufsm.br/sociaisehumanas/article/download/6054/pdf>. Acesso em: 06 set. 2018.

Aula 5

Ferramentas para o controle da qualidade:
diagrama de causa e efeito e histograma

Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. saber como utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. conhecer o diagrama de causa e efeito ou também conhecido por espinha de peixe ou diagrama de Ishikawa;
3. conhecer uma ferramenta usada para dados de frequência, o histograma.

Pré-requisitos

Funções estatísticas e distribuição normal, ciclo PDCA, estratificação e folha de verificação, conteúdos abordados nas aulas anteriores.

Introdução

A busca pela manutenção e melhoria da qualidade pelas organizações é um trabalho árduo e incansável. Para que os resultados sejam alcançados, elas fazem uso de diversos modelos e ferramentas para identificar o mais cedo possível os problemas, compreender sua dinâmica e atuar para sanar as causas-raiz, alcançando, assim, patamares cada vez mais elevados de qualidade.

Dois ferramentas de grande relevância nessa empreitada são o diagrama de causa e efeito e o histograma. A primeira permite identificar potenciais causas de determinado problema ou falha, permitindo, assim, que o processo investigativo sobre os problemas possa se desenvolver e as reais causas a serem combatidas sejam identificadas. O histograma, por sua vez, permite analisar de forma visual os resultados de determinado processo, de tal forma que eventuais situações atípicas, que podem ser indício de um problema no processo produtivo possam ser detectadas, disparando, assim, o processo de análise para identificação das causas.

A combinação de tais ferramentas junto a outras, como estratificação, folha de verificação e diagrama de dispersão gera um robusto arsenal de trabalho para as organizações que buscam a melhoria contínua da qualidade. É isso que você estudará aqui: você verá o que é o diagrama de causa e efeito, como é construído e como é utilizado para o controle da qualidade. Conhecerá, também, o uso e as aplicações do histograma. Bons estudos!

O processo de manutenção e melhoria da qualidade demanda que eventuais falhas, problemas e defeitos ocorridos sejam identificados, analisados, compreendidos e, a partir daí, que sejam estabelecidas ações para solucionar os problemas e impedir novas ocorrências. As denominadas ferramentas da qualidade são instrumentos que facilitam tais passos. Por exemplo, as folhas de verificação são utilizadas para coleta de dados que são estratificados para identificar padrões e fenômenos; o diagrama de dispersão permite analisar a existência de correlação entre variáveis, isto é, inferir se uma pode ser causa da outra, o gráfico de Pareto permite identificar os problemas mais relevantes e que devem ser foco prioritário de análise, etc.

Nessa linha, duas ferramentas adicionais existentes corroboram com tais análises: o diagrama de causa e efeito e o histograma. O primeiro, desenvolvido por Kaoru Ishikawa (1915-1989), é uma ferramenta que

direciona esforços imaginativos dos envolvidos no processo de controle da qualidade para identificarem potenciais causas-raiz dos problemas. Tal ferramenta é também conhecida como diagrama de espinha de peixe, devido ao ser formato, e diagrama de Ishikawa, em homenagem ao seu criador.



Figura 5.1: Kaoru Ishikawa (1915-1989). Engenheiro, foi membro do grupo de pesquisa do controle de qualidade da JUSE (Union of Japanese Scientists and Engineers). O diagrama desenvolvido por ele (denominado, por isso, diagrama de Ishikawa) foi adotado por William Edwards Deming (1900-1993) como uma das ferramentas da qualidade.

Fonte: <https://history-biography.com/kaoru-ishikawa/>

A segunda ferramenta, o histograma, é uma ferramenta que representa graficamente a distribuição de dados coletados. O formato adotado do gráfico pode indicar alguma forma de anomalia nos processos produtivos, sendo, portanto, uma ferramenta que auxilia na detecção e análise de problemas.



Figura 5.2: Histograma. Os dados coletados são distribuídos em classes e um gráfico com barras verticais expõe tal distribuição. O formato adotado pelas colunas que compõem o histograma dá indícios de que o processo que gerou os resultados está funcionando bem ou se há algum problema, o que faz disparar um processo de investigação sobre as causas-raiz.

Fonte: <https://pixabay.com/pt/o-histograma-gr%C3%A1fico-de-histograma-3173455/>

Ferramentas para o controle da qualidade

Como você viu nas Aulas 3 e 4, são sete as ferramentas para o controle da qualidade:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de Pareto;
- diagrama de causa e efeito;
- histograma;
- gráficos de controle.

Nas citadas aulas, você estudou as quatro primeiras ferramentas: estratificação, folha de verificação, diagrama de dispersão e gráfico de Pareto. Tais ferramentas não são de uso mutuamente excludente, ou seja, não é necessário escolher-se somente uma delas para as ações referentes à manutenção e melhora da qualidade.

Ao contrário, tais ferramentas se complementam no uso. E o mesmo se aplica às duas ferramentas que estudaremos nessa aula: o diagrama

de causa e efeito e o histograma, ferramentas muito úteis para a detecção antecipada de problemas, sua análise e identificação de potenciais causas-raiz. Vamos estudar cada uma delas, bem como suas inter-relações com as demais ferramentas e aplicações para a manutenção e melhoria da qualidade.

Diagrama de causa e efeito

O diagrama de causa e efeito – que, como você já leu, também, é conhecido como diagrama de Ishikawa e tem sua lógica fundamental calcada no *brainstorming*, que traduzido, ao pé da letra, seria algo como “tempestade mental” – é uma ferramenta utilizada para gerar ideias, sendo aplicado em diversas áreas. Conforme Baxter (2003), o termo *brainstorming* foi cunhado por Alex Osborn em 1953, em seu livro *Applied Imagination*, caracterizado por incitar as pessoas a gerarem a maior quantidade de ideias que elas conseguirem, sem se preocuparem se estas terão uso ou não, se são lógicas ou não. Não há crítica e, assim sendo, esse foco na “quantidade” torna o *brainstorming* uma potente ferramenta de incentivo à criatividade, pois são quebrados os bloqueios mentais que usualmente existem e que limitam o potencial criativo.

Há diversos modelos de *brainstorming*, bem como ferramentas variantes dele: no modelo tradicional, conhecido como “livre” (ou livre rodada), os participantes expressam livremente suas ideias, ao serem encorajados a contribuir ao acaso com tantas ideias quanto desejarem, até que mais ninguém tenha nada a acrescentar (XEROX, 1985).

Como há a possibilidade de alguns indivíduos dominarem a sessão, enquanto outros, mais tímidos, podem relutar em dar suas contribuições, foi proposta uma forma diferenciada de desenvolver o *brainstorming*, no formato chamado de “rodada”, no qual é solicitado, em sequência previamente determinada (por exemplo, na sequência da posição em que estão sentados), a cada participante que contribua com uma ideia, em rodadas sucessivas (caso a pessoa “da vez” não tenha qualquer ideia, avança-se para o próximo, dando continuidade ao processo, até que ninguém mais tenha a contribuir). É um método interessante, no qual, além de evitar que haja o domínio da discussão por alguém, todos são encorajados a participar, o que pode ser muito bom para os participantes que ainda não estão totalmente familiarizados com o *brainstorming* convencional. No entanto, pode surgir alguma ansiedade enquanto os participantes esperam por sua vez, além do fato de que a criatividade

pode ser menos intensa do que no método convencional, pois, sendo um processo mais ordenado, não há um clima tão dinâmico, além do que, com a espera da rodada, algumas ideias podem ser esquecidas (XEROX, 1985).

“O *brainwriting* é uma evolução do *brainstorming*, procurando conservar suas vantagens, enquanto reduz suas desvantagens” (BAXTER, 2003, p.71): o grupo escreve suas ideias de forma individual até o esgotamento, sem dividi-las com o resto do grupo. Somente ao ocorrer o esgotamento de um dos membros, este consulta os papéis de outro participante. Depois que as ideias foram geradas no papel, faz-se uma sessão convencional de *brainstorming*, buscando-se uma ideia completamente nova (BAXTER, 2003).

Um modelo parecido é o do denominado “anotações em papel”. Ele inicia da mesma forma, com cada participante escrevendo suas ideias individualmente, mas não há a consulta às ideias de outros: isso ocorre somente no final, quando os papéis são recolhidos e as ideias escritas em um quadro visível a todos, e pode servir como etapa inicial para os métodos de rodada e livre direção, com as contribuições permanecendo anônimas.

O método de “informações coletivas” guarda certa similaridade com os anteriores. Desenvolvido pela Proctor & Gamble, cada membro recebe um papel com o problema escrito na parte superior, tendo um prazo (normalmente um mês) para colocar suas ideias, a uma taxa de pelo menos uma por dia. Ao fim do período estipulado, as ideias são reunidas em um único documento e cópias são enviadas aos participantes ou uma sessão de *brainstorming* é organizada para discutir as soluções propostas, buscando estimular-se o aparecimento de novas ideias e/ou a combinação das existentes (BAXTER, 2003).

E como o *brainstorming* é utilizado no diagrama de causa e efeito? Ou seja, por que não usar simplesmente o *brainstorming*, mas sim usar outra ferramenta que se baseia nele? A resposta a tal questionamento é que, ainda que mantido o incentivo à participação, colaboração e criatividade e imaginação, o diagrama de causa e efeito auxilia a direcionar tais esforços de forma estruturada e estratificada. A ideia é identificar potenciais causas de determinado problema; trata-se, portanto de um processo que faz parte da análise de um problema identificado. Mas, apesar de identificado, suas causas-raiz são, a princípio, desconhecidas, sendo necessário um processo investigativo para identificá-las e atuar sobre elas.

É aí que entra o valor da geração de ideias: a criatividade e a inventividade podem identificar potenciais causas que talvez não fossem pensadas sem um método como o *brainstorming*. Quanto mais ideias sobre as potenciais causas, maior a possibilidade de algum(as) delas ser(em) causa(s) real(is). Ou seja, não se busca saber quais são as causas-raiz, mas, primeiramente, identificar quais podem ser. O processo de validação, isto é, identificar quais das potenciais causas têm, de fato, influência sobre os problemas, é feito posteriormente, normalmente utilizando ferramentas como o diagrama de dispersão, o cálculo do coeficiente de correlação entre a potencial causa e o efeito (o problema estudado) (vide Aula 3).

Assim, voltando ao questionamento inicial, o que diferencia o diagrama de causa e efeito dos demais tipos de *brainstorming*? Bem, primeiramente, sendo um diagrama, é uma representação gráfica e a lógica de tal representação é que a torna tão especial: ela prevê que as potenciais causas sejam estratificadas e posicionadas em “grupos”. Tais grupos, ainda que não mandatoriamente, são chamados de “6 Ms”, em alusão às iniciais de cada grupo: método, material (ou matéria-prima), mão-de-obra, máquina, medida (ou medição) e meio ambiente (ou simplesmente “meio”).

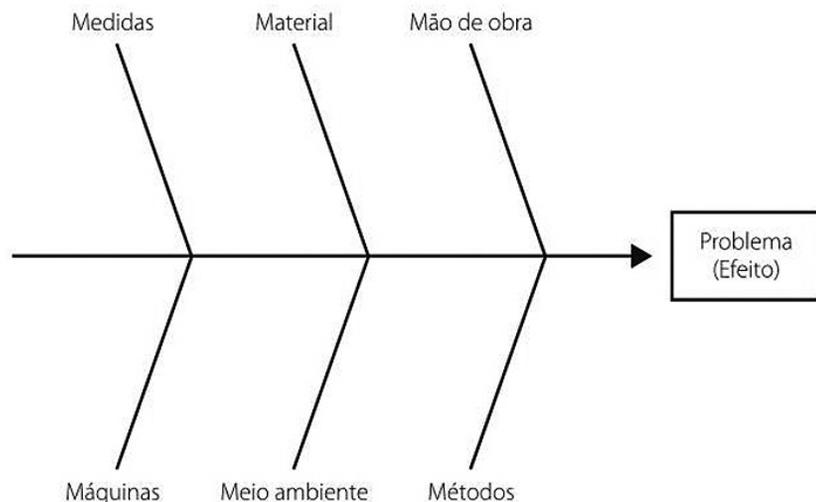


Figura 5.3: Exemplo de diagrama de Ishikawa. A partir do problema (colocado à direita), são desenhadas ramificações que representam os grupos de causas potenciais do problema. Repare que as ramificações criam um efeito que faz com que o diagrama se pareça com espinhas de peixe. Por esta razão, o diagrama é também conhecido como diagrama espinha de peixe.

Fonte: Ramos, Almeida e Araújo (2013, p. 13).

Ou seja, determinado problema pode ser causado pelo método produtivo (por exemplo, um método inadequado, que não garanta que os produtos fiquem de acordo com a especificação). A causa pode ser, também, uma matéria-prima não conforme (por exemplo, com composição química ou características físicas inapropriadas), ou pode ter como causa um erro na operação (uma falha da mão de obra). Pode, também, ter sua origem em uma falha da máquina ou do equipamento utilizado no processo (ex: folgas excessivas, vibração, componentes soltos, etc.). É possível, também, que o problema esteja relacionado ao processo ou a ferramentas de medição, como na falha de um sensor de leitura, ou mesmo no uso de instrumento inadequado. Ou ainda, o ambiente pode ser o causador do problema, por exemplo, por contaminação, temperatura ou umidade inadequada, etc.

O processo de elaboração do diagrama ocorre mediante um *brainstorming* para identificar as potenciais causas do problema, sendo que tais causas (as ideias que surgem no *brainstorming*) são “encaixadas” nos grupos, ou seja, em cada um dos 6 Ms. As potenciais causas devem ser indicadas e, mantendo a lógica da representação gráfica, é importante tê-las de forma facilmente visualizável, como mostrado na figura a seguir.

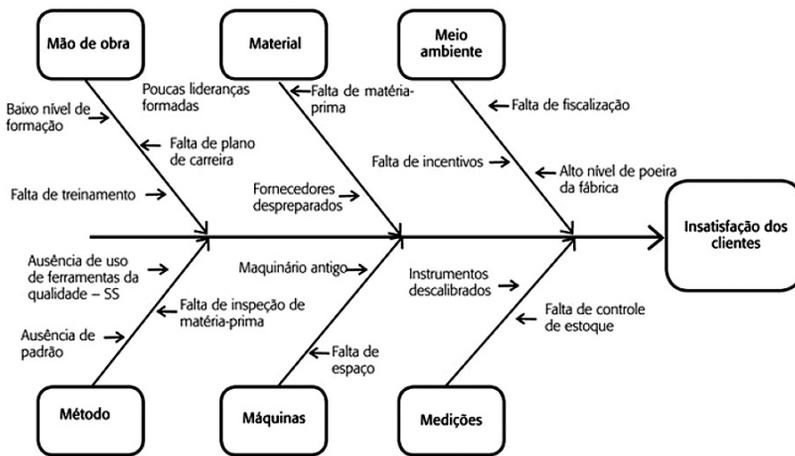


Figura 5.4: Exemplo de diagrama de causa e efeito. Nos ramos (ou nas espinhas do peixe), são posicionadas as potenciais causas-raiz do problema, identificadas no processo de *brainstorming*. A partir do problema (colocado à direita), são desenhadas ramificações que representam os grupos de causas potenciais deste. Repare que as ramificações criam um efeito que faz com que o diagrama se pareça com espinhas de peixe. Por esta razão, o diagrama é também conhecido como diagrama espinha de peixe.

Fonte: Rocha et al. (2014).

Desta forma, ainda que mantida a lógica do *brainstorming* de geração de muitas ideias, sem que haja, muitas vezes, uma ordem, no caso do diagrama de causa e efeito, o *brainstorming* é “direcionado” para as ramificações, isto é, para os 6 Ms. Mas, e se você quiser fazer uma análise em que os 6 Ms não pareçam adequados, devido a alguns ramos não serem representativos na situação que é estudada e/ou alguns temas serem mais relevantes? Em situações específicas, tais ramos podem ser distintos dos 6 Ms, abordando grupos diferentes, como mostrado nas figuras a seguir.



Figura 5.5: Exemplo de diagrama de causa e efeito. Como você pode observar, há quatro ramos e três deles são comuns aos 6 Ms, porém com nomes distintos: equipamentos (ao invés de máquinas); procedimentos (ao invés de método) e pessoal (ao invés de mão de obra). Já o quarto ramo aborda “políticas”.

Fonte: Santos (2009, p. 15).

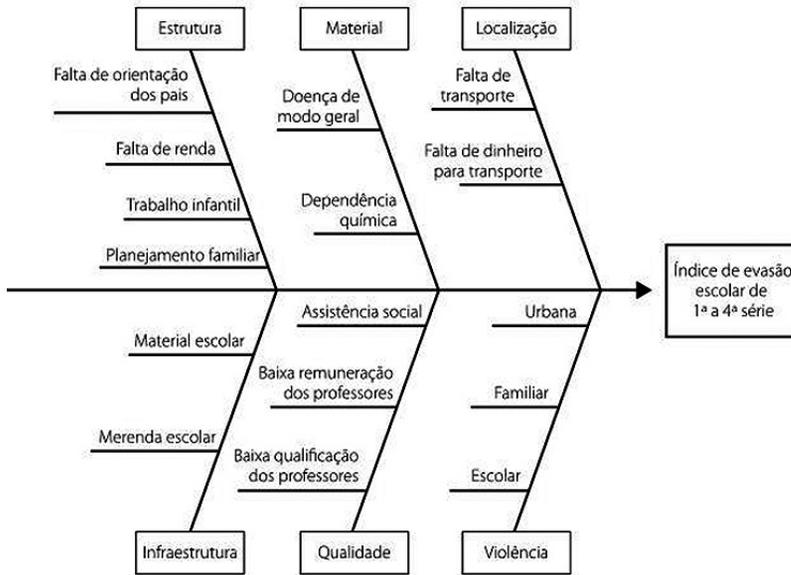


Figura 5.6: Exemplo de diagrama de Ishikawa utilizado para identificar as potenciais causas do alto índice de evasão escolar. Repare que, por conveniência do estudo, há os ramos: estrutura, localização, infraestrutura, qualidade e violência.

Fonte: Ramos, Almeida e Araújo (2013, p. 14).

Repare como, nos exemplos, há “ramos” específicos, como políticas da empresa, violência, etc. Ou seja, são situações em que as divisões dos ramos foram customizadas para um contexto mais adequado de análise. De acordo com Christo (2017, p. 5), é necessário “identificar causas secundárias que afetam as primárias”, o que é feito mediante o desdobramento dos ramos em sub-ramos, isto é, em causas secundárias, como mostrado na figura a seguir.

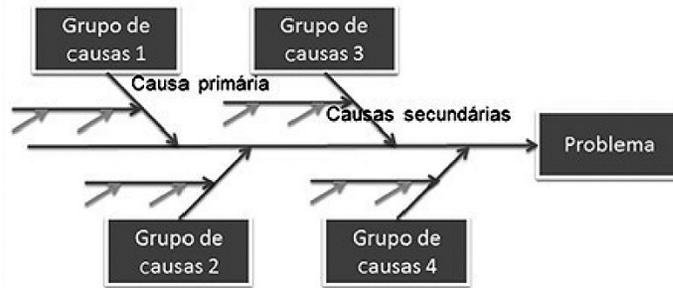


Figura 5.7: Exemplo de diagrama de Ishikawa com o desdobramento das causas primárias em causas secundárias. Ainda que, hipoteticamente, o desdobramento pudesse continuar para identificar causas terciárias, isto não é usual, por tornar o diagrama excessivamente confuso. Nesses casos, é preferível que sejam construídos diagramas separados das causas primárias/secundárias, como parte do processo de análise do problema.

Fonte: Joia et al. (2013, p. 47).

O desdobramento das causas primárias em secundárias ocorre pelo fato de que, de uma forma geral, as causas primárias são generalistas, eventualmente, não permitindo plena compreensão do fenômeno e, conseqüentemente, tornando difícil o estabelecimento de ações de validação e desenvolvimento de contramedidas. Dessa forma, desdobrar as análises e as ideias, procurando identificar potenciais “causas das causas” é uma boa prática.

A lógica de tal desdobramento é semelhante à da ferramenta denominada “5 porquês” (ou *5 whys*, em inglês), que “consiste em perguntarmos sucessivamente a razão da ocorrência de um evento, para que possamos chegar à sua real causa. A cada etapa (ou seja, a cada pergunta e resposta), nos aprofundamos na pesquisa sobre o problema e temos melhor compreensão de sua dinâmica de ocorrência” (ROCHA, 2019, p. 163).

Como você pode perceber, as ferramentas da qualidade seguem uma lógica interessante, baseada no questionamento constante, de forma a buscar o conhecimento sobre determinado problema e sua dinâmica de ocorrência a partir da causa-raiz. Baseiam-se, também, no uso de modelos gráficos e de visualização, de forma a tornar fenômenos, ações e relações entre variáveis mais facilmente perceptíveis (você já ouviu o ditado “uma imagem vale mais que mil palavras?”).

Além disso, as ferramentas, apesar de terem usos específicos, normalmente são utilizadas em conjunto, com uma ferramenta gerando subsídios para outra, garantindo um percurso robusto em direção à manutenção e melhoria contínua da qualidade. Vamos ver mais uma dessas ferramentas: o histograma.

Histograma

O histograma – também conhecido como diagrama de frequências ou de distribuição de frequências – é mais uma ferramenta que tem forte apelo visual: por meio dele é possível visualizar fenômenos que não seriam perceptíveis mediante a observação de dados em uma lista ou tabela.

Na verdade, a lógica do histograma é muito interessante: propositalmente perde-se parte da precisão dos dados para que, em contrapartida, seja possível ter uma visão do “todo”. Você acha isso estranho e mesmo contraditório? É o mesmo recurso utilizado quando, por exemplo, nos afastamos de uma árvore, para podermos identificar se ela está sozinha ou se faz parte de uma floresta. Ou seja, conseguirmos ter uma visão mais ampla.

Que fenômenos podem ser visualizados com o histograma? “Sua utilização permite a demonstração das variações ocorridas nos dados de determinados intervalos, apresentando a tendência central, grau de dispersão e formato de uma distribuição estatística” (LOZADA, 2017, p. 31). Isso é feito mediante a construção de um gráfico de barras em que a altura das colunas representa a frequência absoluta ou relativa das ocorrências dos eventos em diferentes classes de intervalos de medidas, como exemplificado na figura a seguir.

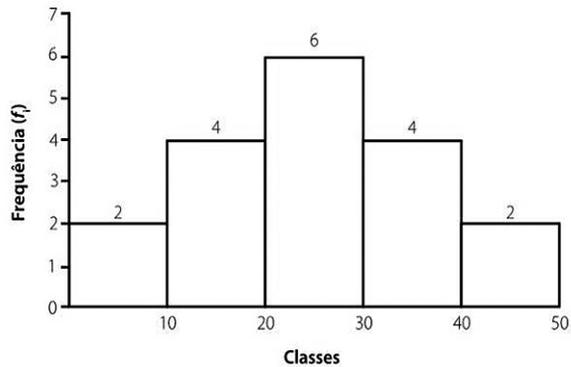


Figura 5.8: Exemplo de um histograma. Nele, há cinco classes de medidas, como pode ser visto no eixo das abscissas (0 a 10; 10 a 20, etc.). As ordenadas, por sua vez, mostram a frequência de ocorrências. Por exemplo, duas ocorrências na primeira classe, quatro na segunda, etc.

Fonte: Ramos, Almeida e Araújo (2013, p. 32).



Anderson, Sweeney e Williams (2002, p. 48) destacam que as barras adjacentes do histograma se tocam: “Diferentemente de um gráfico de barras, um histograma não tem uma separação natural entre os retângulos das classes adjacentes. Esse formato é uma convenção usual para histogramas”.

Obs: Para variáveis discretas, não utilizar áreas e sim linhas (CHRISTO, 2017, p. 11).

O histograma nos auxilia a identificar e compreender problemas pela forma assumida pelas barras de frequência: como você pode observar na figura anterior, há uma concentração de valores em uma região central de medidas (20 a 30), ao passo que, conforme os valores se afastam dessa medida central, a frequência diminui de forma acentuada. Trata-se de um sinal de que, qualquer que seja o processo estudado, ele parece ser normal e adequado, justamente por tal característica: por exemplo, se medirmos a altura das pessoas em determinado grupo, o usual é que tenhamos uma proporção significativa de pessoas com o

que podemos chamar de “altura mediana”, ao passo que uma quantidade menor de pessoas seria classificada como muito altas ou muito baixas. Também, se pensarmos nas medidas de um lote de peças fabricadas, é esperado que tenhamos uma grande quantidade de peças com medidas próximas, ao redor de um valor médio, havendo poucas peças muito abaixo ou muito acima de tais valores.

Esse fenômeno, por sinal, é o que caracteriza a distribuição da curva normal, também conhecida como distribuição gaussiana, que “aparece em inúmeros fenômenos físicos básicos” (MONTGOMERY; RUNGER, 2009, p. 74). A semelhança entre a disposição das barras e a curva normal pode ser observada na figura a seguir.

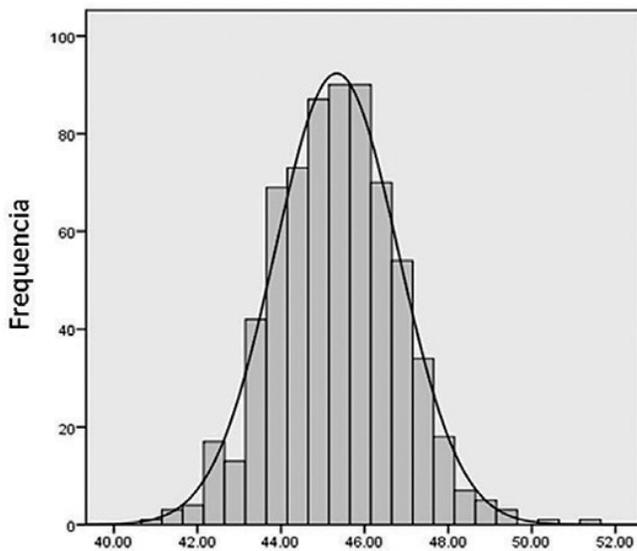
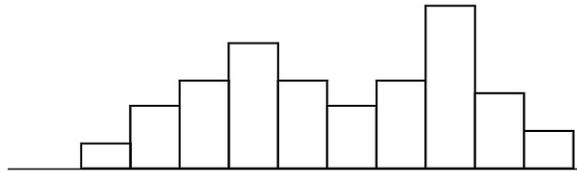


Figura 5.9: Exemplo de um histograma com a sobreposição de uma curva normal. Repare que, ainda que o encaixe não seja perfeito, o formato da curva é bem evidente quando consideradas as alturas das barras. Além disso, a distribuição é basicamente simétrica e decresce com o afastamento dos valores centrais.

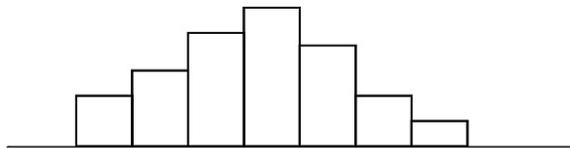
Fonte: Adaptado de Lopes et al. (2014, p. 17).

Como cita Christo (2017, p. 12), o histograma simétrico tem o formato de “sino”, com o valor médio localizado em seu centro e “O processo geralmente está sob controle, somente causas comuns estão presentes”. Mas se esse é o padrão esperado em um histograma, que tipo de distribuições você imagina que poderiam ser encontradas, que indicariam algum problema potencial? Santos (2009, p. 30) mostra algumas possibilidades:

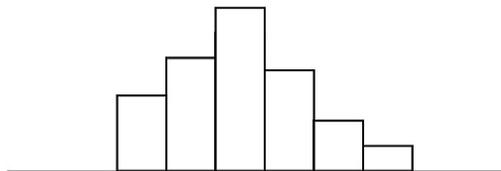
Histograma bi ou multimodal: Representa processos diferentes (ou a populações diferentes), cujas amostras estão misturadas. A solução é separar as populações e refazer a análise.



Dispersão exagerada: A variância é muito grande (boca do sino muito aberta). A solução é verificar e eliminar as causas de dispersão.

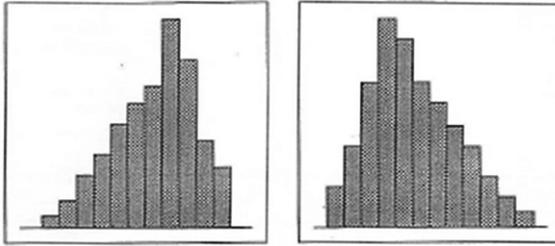


Truncamento (à esquerda ou à direita): Existe a presença de fatores não estatísticos que “truncam” a normalidade de distribuição. Tais fatores são normalmente devido a equipamento (por exemplo, uma balança que “agarra”).

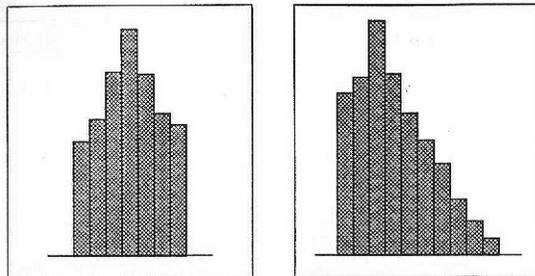


Christo (2017, p. 13-15) apresenta outras possibilidades:

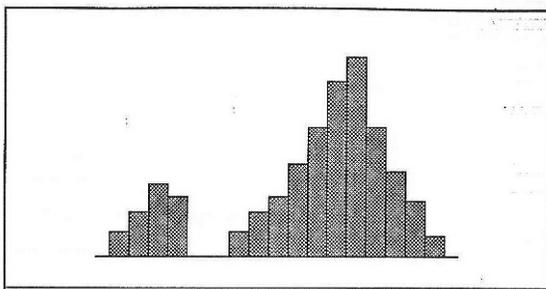
Histograma assimétrico: Valor médio localizado fora do centro, a frequência diminui gradativamente de um dos lados e de forma abrupta do outro. Ocorre quando a variável possui apenas um limite de especificação.



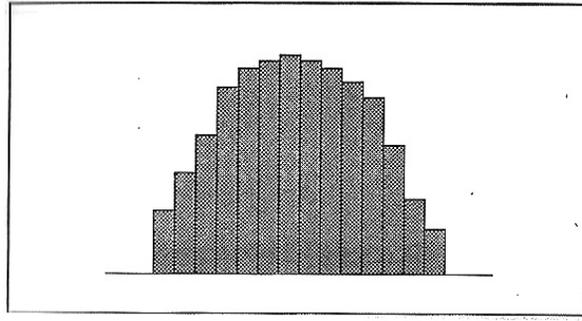
Histograma despenhadeiro: Valor médio localizado fora do centro, a frequência diminui de forma abrupta em um dos lados ou nos dois. Ocorre quando o processo não atende às especificações.



Histograma ilhas isoladas: Trata-se de um caso extremo de histograma bimodal. Dados provenientes de distribuição diferente da distribuição da maior parte dos dados, podendo ocorrer quando existe alguma irregularidade no processo ou pode estar associado a erros de medida e registro de dados.



Histograma achatado (platô): Todas as classes possuem aproximadamente a mesma frequência (exceto as da extremidade). Ocorre com duas distribuições com médias não muito diferentes.



Perceba, então, que a análise do histograma é feita visualmente. Isso significa que basta criar um gráfico e conseguiremos fazer tal tipo de análise?

Na verdade, não: para que tal análise possa ser feita de forma adequada, é necessário que o histograma seja construído corretamente, pois erros na construção podem levar a interpretações errôneas do gráfico.

A construção dos histogramas deve seguir os seguintes passos (SANTOS, 2009; CHRISTO, 2017; LOZADA, 2017):

1. coletar os dados pertinentes, os quais são identificados por meio de estratificação e alguma forma de folha de verificação;
2. identificar a quantidade de dados (n);
3. identificar o maior valor (M) e o menor (m) dentre os dados coletados;
4. calcular a amplitude total (R), sendo $R = M - m$;
5. estabelecer a quantidade de classes (k). Para tanto, há diversas alternativas presentes na literatura (SANTOS, 2009; LANE et al., [20??]; CHRISTO, 2017; LOZADA, 2017):

(i) $k = \sqrt{n}$;

(ii) κ é o menor inteiro tal que $\kappa > 1 + 3,322 \log_{10}(n)$ (Regra de Sturges);

(iii) $k = \sqrt[3]{n}$;

(iv) por meio de tabelas, como a mostrada a seguir.

Tabela 5.1:

n	k	n	k
20 - 50	6	< 50	5 a 7
51 - 100	7	De 50 a 100	6 a 10

101 - 200	8	De 100 a 250	7 a 12
- 500	9	>250	10 a 20
501 - 1000	10		
> 1000	11 a 12		

Você pode estar se perguntando: e se forem poucos valores, como devemos utilizar a tabela? Nesse caso, ela não serviria? Bem, ainda que a tabela mostre a possibilidade de trabalhar-se com poucos dados (*n* a partir de 20 medidas), a visualização de fenômenos com tão poucos dados é difícil. Nesses casos, a recomendação é trabalhar-se com outra ferramenta, o **boxplot**.

6. calcular a amplitude aproximada das classes $(AAC) = R / k$;
7. arredondar AAC para um valor mais conveniente;
8. estabelecer os valores iniciais e finais de cada classe (menor valor e maior valor);
9. construir a tabela de frequências, contabilizando a quantidade de dados em cada uma das classes;
10. construir o gráfico, com base nos dados da tabela.

Boxplot (ou caixa de medianas)

“É um resumo gráfico do modelo de variação de um conjunto menor do que 40 dados ou da comparação de distribuições diferentes, tendo, dessa forma, a mesma função do histograma” (SANTOS, 2009, p. 27).

Vamos tomar como exemplo os dados apresentados por Lozada (2017), referentes a dimensões de determinado lote de produtos, mostrados a seguir.

Tabela 5.2:

12,58	12,97	13,45	13,53	13,59	13,61	13,62	13,78	13,97	14,21
14,47	14,51	14,53	14,58	14,65	14,78	14,83	14,97	15,06	15,13
15,17	15,23	15,29	15,37	15,40	15,45	15,51	15,62	15,67	15,73
15,83	15,98	16,01	16,11	16,17	16,23	16,35	16,43	16,49	16,52
16,67	16,83	16,97	17,05	17,13	17,22	17,30	17,48	17,80	18,47

Como você pode apurar, foram coletadas 50 medidas, sendo a maior delas 18,47 e a menor, 12,58. Logo, temos:

$n = 50$;

$$M = 18,47 \text{ e}$$

$$m = 12,58.$$

$$\text{Assim, } R = 18,47 - 12,58 = 5,89.$$

Vamos calcular o valor de k de acordo com as alternativas anteriormente mostradas:

$$(i) k = \sqrt{50} \approx 7;$$

$$(ii) 1 + 3,32 \log_{10}(50) = 6,6. \text{ Assim, o menor inteiro nos dá que } k = 7;$$

$$(iii) k = 2 \times \sqrt[3]{50} \approx 7;$$

(iv) pela tabela, encontramos “de 6 a 10 na primeira” e “6” na segunda.

Desta forma, o valor de $k = 7$ parece ser o mais apropriado, quase um consenso entre os diferentes métodos. Calculamos, então, a amplitude aproximada das classes (AAC) = $5,89/7 \approx 0,84$, o qual arredondaremos, por uma questão de conveniência para facilidade de cálculos, para 0,85.

Observe que, com sete classes de amplitude 0,85, teremos uma amplitude total de $7 \times 0,85 = 5,95$, que é ligeiramente superior à amplitude total dos dados (R), o que é aceitável e adequado (não poderia ser inferior, pois se isso acontecesse, não haveria como alocar os dados extremos (menores ou maiores valores)).

Com essa pequena “folga” nas amplitudes, podemos estabelecer os limites de cada classe. Arredondamos, então, o início da primeira classe, visando fazer com que os valores extremos fiquem aproximadamente equidistantes do menor valor da primeira classe e do maior valor da última classe, como mostrado a seguir:

Tabela 5.3:

Classe	Min	Max
1	12,55	13,39
2	13,40	14,24
3	14,25	15,09
4	15,10	15,94
5	15,95	16,79
6	16,80	17,64
7	17,65	18,49

Com as classes estabelecidas, podemos, agora, contabilizar quantas medidas dentre as 50 são encontradas em cada classe, isto é, quantas ocorrências temos entre 12,55 e 13,39 (classe 1); quantas entre 13,40 e 14,24 (classe 2); etc., completando a tabela, em preparação para a construção do gráfico. Nela, podemos, também, calcular as frequências relativas, ou seja, a proporção percentual da quantidade de ocorrências em cada classe (sobre o total de 50 medidas presentes no nosso exemplo). O resultado é mostrado na tabela expandida a seguir.

Tabela 5.4:

Classe	Min	Max	Freq absoluta	Freq %
1	12,55	13,39	2	4%
2	13,40	14,24	8	16%
3	14,25	15,09	9	18%
4	15,10	15,94	12	24%
5	15,95	16,79	10	20%
6	16,80	17,64	7	14%
7	17,65	18,49	2	4%
TOTAL			50	100%

Temos, assim, todas as informações necessárias para construir o histograma, tanto por frequência absoluta como por relativa (%), como mostrado a seguir.

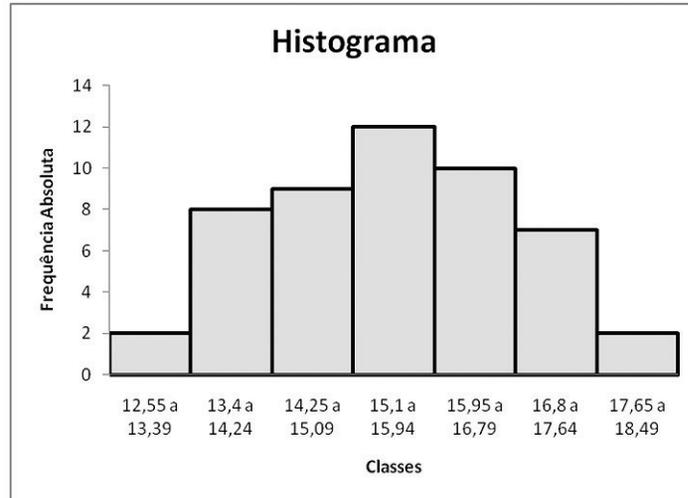


Figura 5.10: Histograma por frequência absoluta, construído a partir das informações coletadas.

Você nota uma semelhança entre os histogramas apresentados? Mera coincidência? Não: a aparência dos gráficos é, de fato, a mesma, o que faz sentido pois a base de dados e as distribuições são exatamente iguais. Somente o fato de o primeiro mostrar a “contagem” das ocorrências, enquanto o segundo apresenta a divisão proporcional, é que faz com que as escalas sejam diferentes (repare nas unidades dos eixos “Y” nos dois gráficos).

Você deve ter percebido, também, que o formato gerado pela altura das colunas se aproxima de uma curva normal (veja a figura seguinte, na qual a curva normal é sobreposta ao histograma).

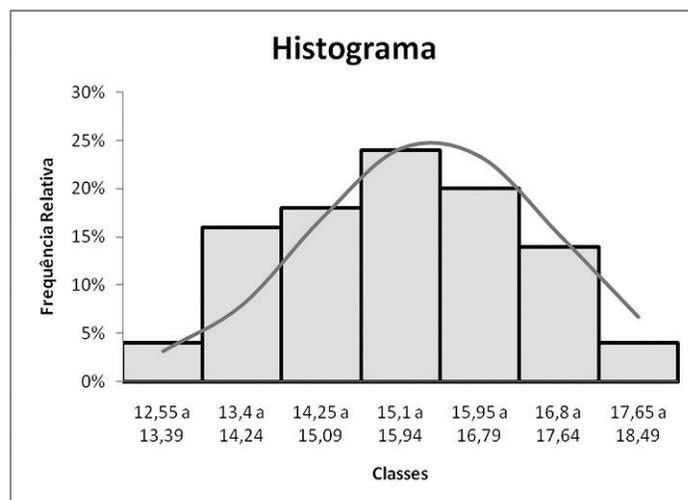


Figura 5.11: Histograma por frequência absoluta, construído a partir das informações coletadas.

Uma dúvida que pode surgir é: e se ao invés de sete classes, tivéssemos escolhido $k = 6$, já que por uma das tabelas, esse deveria ser o valor, o que aconteceria? Bem, veja a seguir como ficaria o histograma nessa situação: os dois gráficos foram colocados lado a lado para que você possa compará-los.

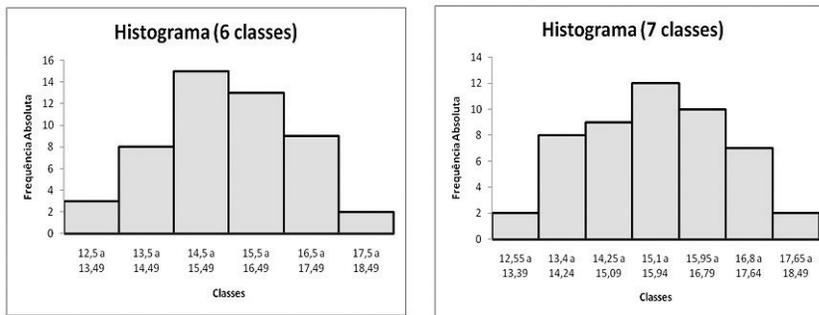


Figura 5.11: Como ficariam os histogramas, caso tivéssemos escolhido $k = 6$.

Perceba que não há uma diferença significativa entre os dois gráficos. Ou seja, ainda que o perfil formado pelas alturas das colunas seja um pouco diferente, não encontramos qualquer indicativo de potencial problema (histograma bimodal, dispersão exagerada, etc.) quando constituímos o histograma com sete classes e nem quando o construímos com seis classes. Ou seja, pequenas diferenças na quantidade de classes usualmente não comprometem a análise visual dos histogramas. E isso faz sentido, visto que os métodos para estabelecer o valor de “ k ” geram números que devem ser arredondados.

No entanto, e se você arbitrariamente estabelecer valores de “ k ” muito diferentes dos propostos nos métodos, o que aconteceria? Nesse caso, as “pequenas diferenças” deixam de ser uma verdade. Por exemplo, como você pode ver nas tabelas que propõem valores para “ k ”, a quantidade mínima de classes é de cinco e isso é compatível com as alternativas em que o valor de “ k ” é calculado. No entanto, se você, arbitrariamente, estabelecesse um valor de “ k ” bem mais alto, por exemplo, $k = 15$, teríamos algo muito diferente. Veja como ficaria o histograma nesse caso:

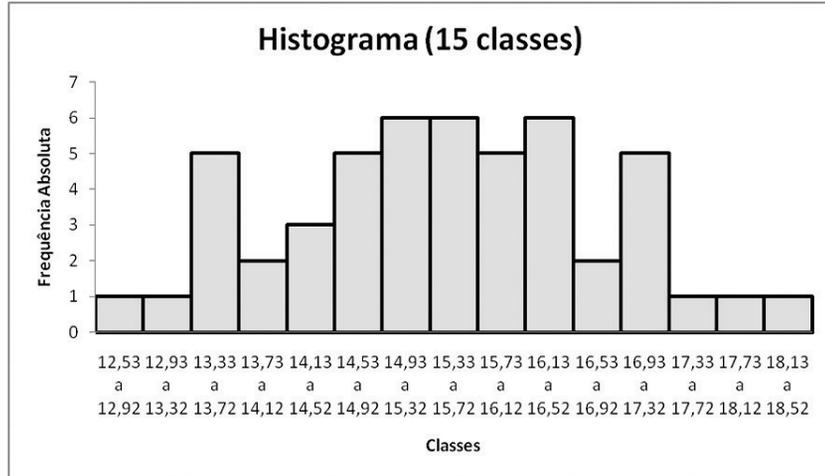


Figura 5.12: Como ficaria o histogramático, caso tivéssemos escolhido $k = 15$.

Repare que, se ainda é possível perceber certa concentração de valores centrais, parece haver um achatamento naquela região, um “histograma achatado” (platô), ou mesmo, temos a impressão de ser um histograma muito “espalhado”, isto é, com dispersão exagerada, aspectos que poderiam caracterizar algum tipo de problema. Ou ainda, perceberíamos alguns “picos” (vide classes 13,33 a 13,72; 16,13 a 16,52; e 16,93, 17,32), que poderiam ser interpretados como um histograma multimodal.

Ou seja, podemos inferir que os métodos para estabelecer a quantidade de classes (k) devem ser seguidos, pois, se utilizarmos valores muito baixos, há o risco de os dados ficarem excessivamente agrupados e, conseqüentemente, não conseguirmos fazer qualquer tipo de análise. Por outro lado, ao utilizarmos “ k ” muito altos, podemos, também ter distorções na avaliação.

==== **Atividade** =====

Atende aos objetivos 1, 2 e 3

A empresa Zezinho's Technology vem enfrentando perdas substanciais nos últimos meses devido à queda nas vendas, aumento dos gastos com garantia, bem como processos movidos por alguns clientes, devido aos defeitos encontrados nos produtos que ela produz. Buscando identificar as causas de tantos problemas, foi feito um levantamento dos defeitos

a cada dia, coletados em folhas de verificação, bem como as condições que se suspeita terem influência sobre os problemas. Em seguida, foi gerado o diagrama de espinha de peixe e, por meio de *brainstorming* e consultas a especialistas, além do uso do 5why's, crê-se que as causas principais sejam os quatro fatores destacados abaixo.

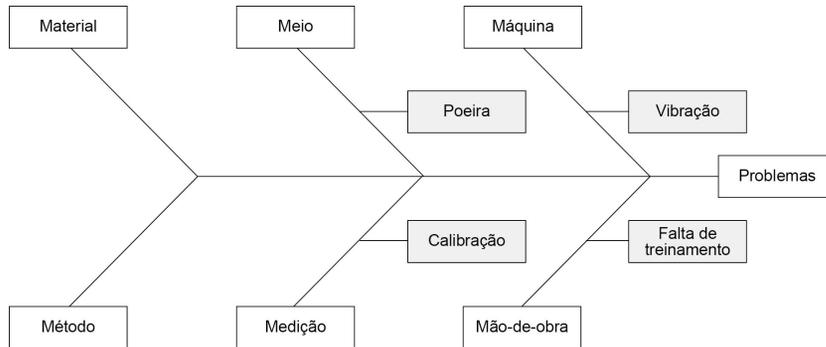


Figura 5.13: Diagrama que mostra as principais causas dos problemas da Zezinho's Technology.

Como parte do processo investigativo, foi medida a resistência mecânica de 120 conjuntos produzidos pela Zezinho's Technology e os resultados de resistência à ruptura em psi são mostrados abaixo.

Tabela 5.5: Resultados de resistência à ruptura em psi

82	84	74	82	79	86	88	93	98	76
82	78	74	82	85	86	89	93	94	76
82	79	75	85	87	90	94	81	84	76
83	76	80	83	85	90	95	81	84	92
83	77	80	83	85	90	85	82	84	92
83	79	81	83	85	91	95	82	85	92
92	96	79	82	99	92	96	82	85	93
92	96	80	83	101	76	81	83	85	93
92	96	80	83	102	78	81	80	83	95
93	93	81	83	103	78	81	81	83	96
93	98	81	83	82	85	86	85	87	96
92	108	85	77	90	85	88	93	93	105

Com base nas informações, pergunta-se:

- a) As ferramentas utilizadas até o momento são adequadas para este tipo de análise?
- b) Você recomendaria o uso de alguma outra ferramenta? Justifique sua resposta.
- c) Os resultados encontrados com relação às medidas de resistência mecânica mostram um processo sob controle?

Resposta comentada

Como foram coletadas informações sobre defeitos a cada dia, houve alguma forma de estratificação dos dados, por meio das folhas de verificação utilizadas para coleta. O uso conjunto do *brainstorming* e do 5 whys (5 porquês) com o diagrama de Ishikawa não somente é adequado, mas recomendado. E a participação de especialistas nesse processo pode ser de grande auxílio. Desta forma, o uso combinado de tais ferramentas parece ter sido bastante adequado, levando à identificação de quatro potenciais causas.

O uso do diagrama de dispersão e o cálculo do coeficiente de correlação para apurar se há influência entre as potenciais causas identificadas seria recomendado para validar ou descartar algumas delas. Também o uso do histograma ou de *boxplots* poderia auxiliar a identificar alguma potencial anomalia nos processos. Além disso, dependendo de como foi a estratificação e a coleta de dados, o uso do diagrama de Pareto poderia auxiliar a priorizar os esforços de investigação, além do ciclo PDCA para guiar os passos do processo de melhoria da qualidade.

Os dados coletados sobre a resistência mecânica podem ser analisados mediante um histograma, o qual é mostrado a seguir.

Como você pode perceber, o gráfico mostra um histograma descentralizado e, principalmente, um perfil bimodal, bastante diferente do que se espera de um processo sob controle (repare como o perfil formado pelas colunas está bastante diferente da curva normal que foi sobreposta. Isso parece ser um indicativo de dados “misturados”, como, por exemplo, dois lotes diferentes e matéria-prima, ou ainda as medições feitas podem ter sido obtidas em instrumentos diferentes, talvez não calibrados (o que foi apontado como uma das potenciais causas do problema).

Já há, assim, algumas trilhas a serem seguidas no processo investigativo, para que a Zezinho's Technology possa reverter a situação e alcançar patamares de qualidade e de satisfação dos clientes mais elevados.

Conclusão

O diagrama de causa e efeito é utilizado para provocar a reflexão e a busca da identificação de potenciais causas de um problema, o uso da citada ferramenta auxilia a disciplinar o processo investigativo do problema, evitando que os envolvidos se limitem a atacá-lo sem compreender quais podem ser as suas causas. Além disso, direciona o processo imaginativo para diferentes classes de causas, evitando a armadilha de se supor que sempre existirá uma única causa para determinado problema ou falha.

O diagrama de causa e efeito não define as reais causas, mas auxilia a identificar quais elas potencialmente são. A validação e definição de quais delas são causas reais do problema, ou não, dependem do uso de outras ferramentas, o que reforça a ideia de que as ferramentas de qualidade se complementam.

Já o histograma, outra ferramenta da qualidade, tem por intuito transformar um conjunto de dados que está em uma lista ou tabela em uma representação gráfica que auxilia a identificação da adequação do processo que gerou tais dados: a forma como os dados são mostrados permite identificar a existência de potenciais problemas. Ou seja, é uma ferramenta de forte apelo visual, na qual a representação gráfica habilita análises que não seriam possíveis mediante a observação dos dados na lista ou tabela que os contém.

Ambas as ferramentas têm seu potencial de benefício ampliado quando utilizadas em conjunto com outras ferramentas da qualidade, como estratificação, lista de verificação, diagrama de dispersão, etc.

Resumo

Para o controle e melhoria da qualidade, é comum a utilização de ferramentas, quais sejam:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de Pareto;
- diagrama de causa e efeito;
- histograma;
- gráficos de controle.

O diagrama de causa e efeito, também denominado de diagrama de Ishikawa (em homenagem a seu criador) ou diagrama espinha de peixe (pelo formato de seu desenho) é utilizado para identificar as potenciais causas do problema, as quais são usualmente classificadas por meio dos denominados 6 Ms: método, material (ou matéria-prima), mão de obra, máquina, medida (ou medição) e meio ambiente (ou simplesmente “meio”).

Já o histograma (ou diagrama de frequências) representa graficamente as frequências (quantidade de ocorrências) de determinado conjunto de dados coletados, que são divididos em classes. O padrão de distribuição, ou seja, o formato adotado pelo gráfico de tais distribuições, permite identificar se as variações são normais ou se há algum sinal de perturbação no processo (o que poderia levar ao surgimento de problemas).

Leituras recomendadas

FEITOSA, Sílvia Moreira et al. Análise comparativa dos histogramas de dose e volume entre planejamentos tridimensionais conformados e convencionais não conformados na radioterapia do câncer de próstata. *Radiol Bras* [on-line], 2009, vol. 42, n.2, p. 69-74. ISSN 0100-3984. Disponível em: <http://dx.doi.org/10.1590/S0100-39842009000200003>. Acesso em: 19 fev. 2019.

HOLANDA, Mariana de Almeida; PINTO, Ana Carla Bittencourt Reis Fernandes. Utilização do diagrama de Ishikawa e *brainstorming* para solução do problema de assertividade de estoque em uma indústria da região metropolitana de Recife. In: XXIX ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. *Anais...*, Salvador, BA, Brasil, 6-9 out. 2009. Disponível em: http://www.abepro.org.br/biblioteca/enegep2009_tn_sto_103_685_13053.pdf. Acesso em: 15 set. 2018.

MACEDO, Rafaela Cristina Rocha; PHILIPPI, Daniela Althoff. Gestão da qualidade: aplicação das ferramentas Brainstorming e Diagrama de Ishikawa. In: CONVIBRA. *Anais...*, 2017. Disponível em: http://www.convibra.com.br/upload/paper/2017/36/2017_36_13984.pdf. Acesso em: 15 set. 2018.

MAGRI, J. M. *Aplicação do método QFD no setor de serviços: estudo de caso em um restaurante* 2009. 43 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Produção) – Universidade Federal de Juiz de Fora, Juiz de Fora, 2009. Disponível em: http://www.ufjf.br/ep/files/2014/07/2009_1_Juliana.pdf. Acesso em: 7 set. 2018.

Informação sobre a próxima aula

Na próxima aula, continuaremos os estudos das ferramentas para o controle da qualidade, trabalhando o gráfico de controle.

Referências

ANDERSON, D. R.; SWEENEY, D. J.; WILLIAMS, T. A. *Estatística aplicada à administração e economia*. São Paulo: Thomson Learning, 2002.

BAXTER, M. *Projeto de produto: guia prático para o design de novos produtos*. 2. ed. São Paulo: Edgard Blucher, 2003.

CHRISTO, E. S. *Aula 4 – Ferramentas para o controle da qualidade*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 5), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=7>. Acesso em: 19 fev. 2019.

JOIA, L. A.; SOLER, A. M.; BERNAT, G. E.; RABECHINI JR., R. *Gerenciamento de riscos em projetos*. 3. ed. Rio de Janeiro: FGV, 2013.

LANE, D. M.; SCOTT, D.; HEBL, M.; GUERRA, R.; OSHERSON, D.; ZIMMER, H. *Introduction to Statistics*. Houston: Rice University, [20??]. Disponível em: http://onlinestatbook.com/Online_Statistics_Education.pdf. Acesso em: 16 set. 2018.

LOPES, B. et al. Bioestatísticas: conceitos fundamentais e aplicações práticas. *Rev. Bras. Oftalmol.*, Rio de Janeiro, v. 73, n. 1, p. 16-22, fev. 2014. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-72802014000100016&lng=en&nrm=iso. Acesso em: 15 set. 2018.

LOZADA, G. *Controle estatístico de processos*. Porto Alegre: SAGAH, 2017.

MONTGOMERY, D. C.; RUNGER, G. C. *Estatística aplicada e probabilidade para engenheiros*. 4. ed. Rio de Janeiro: LTC, 2009.

RAMOS, E. M. L. S.; ALMEIDA, S. S.; ARAÚJO, A. R. *Controle estatístico da qualidade*. Porto Alegre: Bookman, 2013.

ROCHA, H. M. Aula 9 – Análise da árvore de falhas. In: ROCHA, H. M. *Confiabilidade*: volume único. Rio de Janeiro: Fundação Cecierj, 2019.

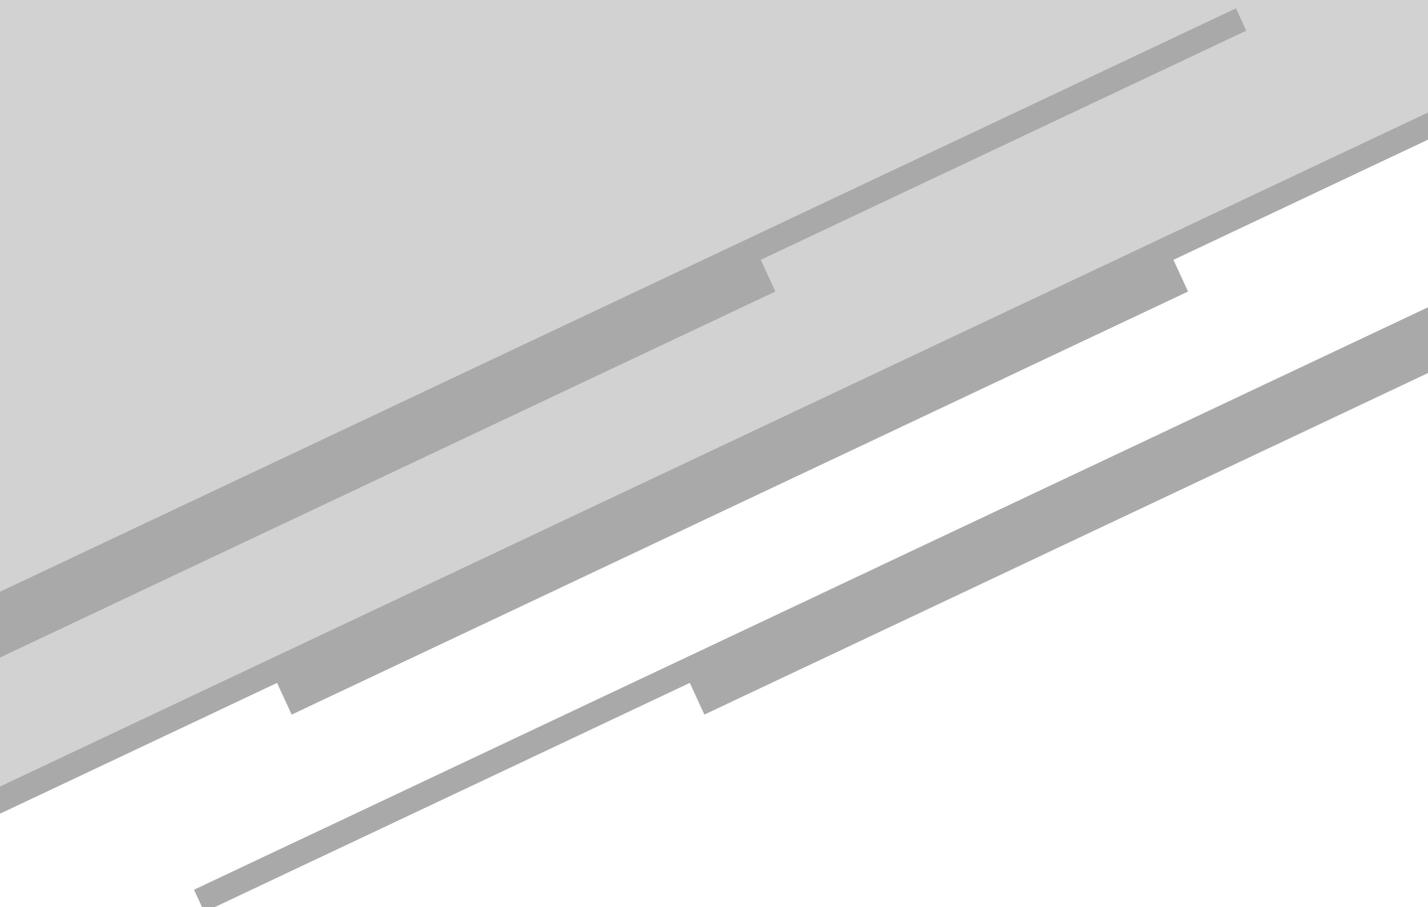
ROCHA, A, V.; COSTA, F. S.; NOGUEIRA, J. F.; BELMIRO, T. R. *Gerenciamento da qualidade em projetos*. Rio de Janeiro: FGV, 2014.

SANTOS, J. A. N. *Análise e melhoria de processos*. Resende: UERJ, 2009.

XEROX. *Liderança através da qualidade*. Distribuição interna, 1985.

Aula 6

Ferramentas para o controle da
qualidade: gráfico de controle



Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. identificar o gráfico de controle ou cartas de controle para variáveis e para atributo, que representa uma das ferramentas mais utilizadas no controle da qualidade.

Pré-requisitos

Funções estatísticas e distribuição normal, ciclo PDCA, estratificação, folha de verificação e histograma, conteúdos abordados nas aulas anteriores.

Introdução

Uma preocupação quanto à manutenção e melhoria da qualidade pelas organizações é a busca incessante por nos anteciparmos aos possíveis problemas, isto é, podermos agir sobre eles antes que ocorram. Mas o que parece ser um exercício de imaginação ou adivinhação pode ocorrer, mediante o uso dos gráficos de controle, que permitem acompanhar o desempenho de produtos e processos, de forma a detectar a ocorrência de fenômenos diversos. Com base nos estudos estatísticos, os gráficos de controle foram responsáveis por grandes mudanças na gestão da qualidade das organizações, aumentando o padrão de qualidade em si, sem que isso representasse, de fato, um aumento nos custos para as organizações.

É isso que você estudará aqui: você verá o que é o gráfico de controle, qual sua lógica construtiva e como é utilizado para o controle da qualidade. Bons estudos!

O processo de manutenção e melhoria da qualidade prevê o uso de ferramentas que auxiliam na detecção, compreensão, análise dos problemas, de forma a permitir a idealização de ações que os evitem, minimizem sua probabilidade de ocorrência, aumentem a chance de sua detecção antes de causarem danos maiores e/ou possibilitem a amortização de seus efeitos.

Dentre as denominadas ferramentas da qualidade, que têm na folha de verificação, na estratificação, no diagrama de dispersão, no diagrama de Pareto e no histograma instrumentos que coletam dados quali-quantitativos que permitem extrair indícios e conclusões sobre determinados fenômenos, existem as denominadas cartas de controle ou gráficos de controle, que permitem compreender o comportamento dos processos, identificando se estes estão “sob controle”, isto é, funcionando conforme previsto e, conseqüentemente, gerando o que é esperado como saída; ou “fora de controle”, quando é possível identificar que “há algo diferente” no processo e, desta forma, há o risco de gerar não conformidades.

Ou seja, com as cartas de controle, criação genial de Walter Shewhart, é possível nos anteciparmos aos problemas, isto é, identificar situações que podem levar à ocorrência destes, havendo, assim, a possibilidade de tomar decisões que evitem danos maiores, antes mesmo que aconteçam.



Figura 6.1: Walter Andrew Shewhart (1891-1967). Formado em Física, trabalhou na Western Electric Company e na Bell Telephone Laboratories, junto a outros “gurus da qualidade”, como Deming e Juran. Além de conhecido como o criador do ciclo PDCA, deve-se a ele a aplicação de estudos estatísticos para manutenção e melhoria da qualidade, sendo chamado de “o pai do controle estatístico da qualidade”.

Fonte: <https://history-biography.com/walter-a-shewhart/>

A ideia básica é a de monitorar os resultados dos processos, de forma a identificar a existência de pequenas variações (usualmente aceitáveis), mas, também, detectar quando variações mais acentuadas ocorrem, de forma a servir como um “alerta” sobre alguma forma de deterioração no processo monitorado. É uma ferramenta mais sofisticada e poderosa que as demais ferramentas da qualidade.

Ferramentas para o controle da qualidade

Como você viu nas Aulas 3, 4 e 5, são sete as ferramentas para o controle da qualidade:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de Pareto;
- diagrama de causa e efeito;
- histograma;
- gráficos de controle.

Nas citadas aulas, você estudou as seis primeiras ferramentas: estratificação, folha de verificação, diagrama de dispersão, gráfico de Pareto, diagrama de causa e efeito e histograma. Por último, vamos agora estudar a mais sofisticada das ferramentas para o controle da qualidade: os gráficos de controle.

Como você viu na Aula 2, há diferenças entre peças, componentes de um lote, entre lotes de produtos, entre processos, etc., da mesma forma que há diferenças entre irmãos gêmeos, mesmo os univitelinos. No caso dos gêmeos, isso acontece porque os fetos têm contato com partes diferentes do espaço do útero da mãe (TER-DF, 2013), razão pela qual eles nunca são totalmente idênticos (mesmo que, algumas vezes, seja difícil identificar diferenças): eles não são clones um do outro, havendo sempre diferenças. Por exemplo, as impressões digitais são diferentes.



Figura 6.2: Impressões digitais. Somos iguais ou diferentes? Ainda que todos nós tenhamos os mesmo direitos e deveres, somos fisicamente diferentes: mais altos ou mais baixos, mais magros ou mais gordos, etc. Mesmo aqueles que são muito parecidos, como os irmãos gêmeos, são diferentes em algum nível, como, por exemplo, nas impressões digitais. Tais diferenças permitem a identificação de cada indivíduo.

Fonte: <https://pixabay.com/pt/impress%C3%A3o-digital-tra%C3%A7os-padr%C3%A3o-456486/>

E esse é um bom exemplo para discutirmos um conceito de extrema importância no que tange ao controle estatístico de processos e, consequentemente, à utilização dos gráficos de controles: as chamadas *causas comuns*

(também chamadas de causas aleatórias) e *causas especiais* (também chamadas de causas atribuíveis ou causas assinaláveis).

Repare que os gêmeos não são, de fato, inteiramente idênticos. Em alguns casos, pode ser até difícil diferenciá-los, mas tudo é uma questão de continuar procurando detalhes até que achemos alguma coisa que os diferencie. E, como citado anteriormente, essas pequenas diferenças se devem a pequenas diferenças no útero da mãe. Mas, isso não significa que eles permanecerão para sempre muito parecidos: diferentes hábitos alimentares, atividades físicas, maior ou menor exposição ao sol, acidentes, enfermidades, etc. são exemplos de aspectos que podem fazer com que os gêmeos se tornem “menos parecidos”: diferenças de peso, estatura, cor da pele (bronzado) e mesmo deficiências físicas ou mutilações tornariam os gêmeos mais “diferentes” um do outro.

Pois bem, fatores de pequeno impacto, que causam as diferenças mínimas (como as diferenças entre gêmeos univitelinos) são chamados causas comuns, ao passo que fatores de maior impacto, que causam maiores diferenças (exemplo: acidentes) são as causas especiais. Mas como tal conceito se aplica a peças, produtos, etc.? Imagine um lote de peças sendo usinadas, todas com o mesmo material, utilizando a mesma máquina, o mesmo processo, etc.



Figura 6.3: Usinagem de peça metálica. Um dos processos de fabricação mais antigos e mais comuns é o de usinagem, que é feito mediante a remoção de materiais por meio de lâminas, facas, pastilhas, etc. O formato final das peças usinadas é dado justamente pela remoção de material, até que reste somente a forma que se deseja (como se fosse uma escultura). Há diversas formas de usinagem: o material pode girar contra uma ferramenta fixa (como no torneamento); a ferramenta pode girar contra o material fixo (como o fresamento), etc.

Fonte: <https://pixabay.com/pt/fresas-ferramenta-moagem-cnc-3738903/>

Será que isso faria com que todas as peças produzidas fossem idênticas? Pense um pouco sobre isso... Será que o material utilizado nas peças, apesar de ser o mesmo, é inteiramente homogêneo ou ele pode ter diferenças mínimas em sua granulação, porosidade, eventuais impurezas, encruamento (deformação plástica em partes do material) em alguns pontos, etc.?

Será que a temperatura ambiente e, em especial, ao redor da máquina permanece exatamente a mesma ao longo da usinagem de todo o lote? Provavelmente não, não é mesmo? E como isso poderia causar diferença entre as peças? Bem, um aumento de 1 °C em uma peça de 1 metro de aço pode ser suficiente para que ela aumente em mais de 0,01 mm o seu comprimento.

E, ainda, como a usinagem envolve movimentos e esforços mecânicos, há vibração durante o processo. A vibração faz com que haja uma tendência de a ferramenta se afastar e se aproximar mais da peça, fazendo com que pequenas imperfeições e variações peça a peça ocorram.

Ou seja, as peças de um lote normalmente são como irmãos gêmeos: muito parecidos, às vezes difíceis de serem diferenciados, mas com detalhes pequenos que os tornam únicos, causados pelas chamadas causas comuns (ex: diferença no material, temperatura, vibrações, desgaste da ferramenta, etc.). Mas esses “irmãos” podem se tornar muito diferentes, caso algo “diferente” aconteça: o suporte da ferramenta pode se afrouxar, fazendo com que ocorram variações substanciais nas dimensões. Ou, ainda, uma falha na matéria-prima pode ser causa de alterações significativas na geometria das peças usinadas, etc. Ou seja, causas especiais podem criar grande diferença nas peças.

A que conclusão chegamos quanto a isso? Que as peças são diferentes entre si, seja devido às causas comuns e, também, às causas especiais? Isso não parece ser novidade: já havíamos discutido isso desde a Aula 2, não é mesmo? Mas, vamos refletir mais um pouco: será que as diferenças devido às causas especiais e devido às causas comuns têm o mesmo efeito sobre as peças e as máquinas e os equipamentos produzidos? Pense um pouco sobre isso...



Figura 6.4: Refletindo sobre causas comuns e causas especiais. Ambas são causa de diferença entre peças, componentes e máquinas e equipamentos em geral. Será que alguma delas é maior causa de preocupação do que outra? Por quê?

Fonte: <https://pt.freeimages.com/photo/face-questions-1567164>

As “pequenas diferenças” são, de uma forma geral, aceitáveis e mesmo previsíveis. Elas são inerentes ao processo produtivo e não costumam gerar qualquer tipo de problema, desde que uma análise prévia da capacidade do processo indique que este é compatível com as necessidades funcionais das peças a serem produzidas.



Refletindo sobre

A palavra capacidade é utilizada na língua portuguesa como a livre tradução da palavra inglesa *capability*, cujo significado é a facilidade ou potencialidade para um uso indicado ou desenvolvimento e desdobramento (ROCHA, 2005). O conceito e cálculo da capacidade de processos serão estudados mais adiante, na Aula 10.

Um processo com maior capacidade gerará menos variações nas peças produzidas. Ou seja, se determinado processo (como, por exemplo, o torneamento) não consegue garantir medidas das peças produzidas

dentro de determinada faixa, o correto é buscar outro processo que garanta maior precisão, menos variabilidade (como, por exemplo, retificar as peças).

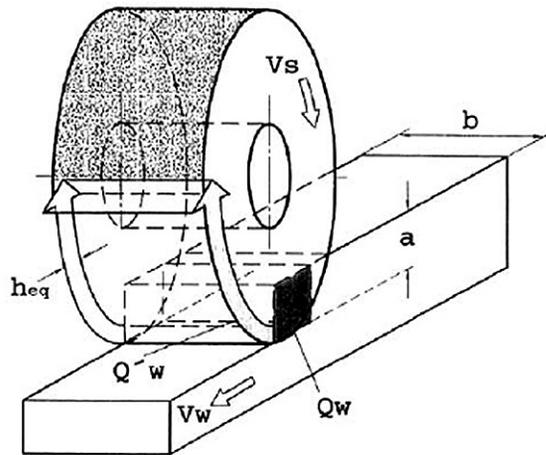


Figura 6.5: Representação esquemática do processo de retificação. O processo de retificação (ou, de forma simplificada, retífica) compreende o uso de materiais abrasivos, na forma de rebolos, discos, rolos, etc. para remover material de peças, garantindo uniformidade na superfície destas e grande precisão dimensional e geométrica das peças produzidas.

Fonte: Fujita et al. (2006, p.273).

Assim sendo, podemos, *grosso modo*, dizer que as “pequenas variações”, oriundas das causas comuns, não são motivo de preocupação. Na verdade, podemos dizer que, por serem inerentes aos processos, elas sempre existirão e que são inevitáveis. No entanto, não podemos inferir a mesma coisa quanto às causas especiais: elas não são previsíveis, tendo como causa de sua ocorrência, problemas específicos, identificáveis, e que, normalmente, nos trazem variações significativas, as quais podem fazer com que as peças produzidas tenham dimensões e características inadequadas ao uso, ou seja, que se tornem não conformes. As causas especiais produzem variações nas características dos produtos em níveis que podem ser inaceitáveis e, por isso, elas devem ser detectadas e evitadas.

E como detectar as causas especiais? Como diferenciá-las das causas comuns? Estas não são perguntas simples, pois, mesmo que inspecionássemos/medissemos as peças, uma a uma, não poderíamos identificar as que fossem não conformes. Afinal, não saberíamos, de fato, se as peças que estivessem ok não foram submetidas a causas especiais.

Certo? Não necessariamente: pode ser que, apesar da causa especial, a discrepância tenha sido inferior ao patamar funcional aceitável. O problema é que, por ser algo imprevisível, a causa especial pode, em outro momento, gerar peças não conformes, o que reforça a necessidade de identificá-las e evitá-las. Além disso, como você aprendeu na Aula 1, a inspeção 100% tem uma série de limitações e problemas.

Assim, a lógica dos gráficos de controle é completamente diferente de tudo o mais que vimos nas outras ferramentas da qualidade: um gráfico de controle, a princípio, não serve para identificar se há peças conformes ou não conformes, mas sim identificar se elas são muito parecidas ou não. Achou estranho? Vamos explicar melhor, voltando ao exemplo dos irmãos gêmeos: como falamos antes, as peças de um lote normalmente são como irmãos gêmeos, isto é, muito parecidos. Isso é o normal, ao passo que irmãos gêmeos muito diferentes seriam algo inesperado (uma causa especial).

Desta forma, os gráficos de controle se prestam a verificar se as peças produzidas são e continuam sendo “parecidas”, pois isso indica que o processo vem sendo mantido. O surgimento de peças “diferentes” (a exemplo dos gêmeos muito diferentes) indicaria alguma alteração no processo.

Você percebe a relação com os conceitos de causas comuns e causas especiais? Peças “gêmeas” indicam haver somente causas comuns, ao passo que peças “diferentes” indicariam a ocorrência de causas especiais, para o que seria necessário iniciar um processo de investigação e análise, visando evitar que eventuais problemas no processo produtivo seguissem adiante.

E repare um aspecto interessante: verifica-se tão somente a similaridade entre as peças e não se elas são conformes ou não conformes. A lógica por trás disso? Bem, se temos peças conformes e as peças são muito iguais, podemos ficar tranquilos, pois todas deveriam estar conformes. Por outro lado, se temos peças conformes, mas elas são muito diferentes, a qualquer momento podemos ter alguma peça não conforme, não é mesmo? Além disso, se produzimos peças não conformes, temos problemas, independentemente de elas serem muito parecidas ou não.

Como são, de fato, os gráficos de controle? E como eles permitem essa avaliação de o processo gerar peças “iguais” (causas comuns) ou diferentes (causas especiais)? Vamos ver isso no próximo tópico.

Gráficos de controle

Como a maioria das demais ferramentas da qualidade, os gráficos de controle têm forte apelo visual, isto é, nos permitem identificar visualmente determinados fenômenos. No caso, o fenômeno que queremos monitorar é a constância nas dimensões selecionadas para análise: queremos saber se o que estamos produzindo é similar ao que produzimos antes.

Entretanto, não podemos esquecer-nos do conceito das causas comuns: o que produzimos agora não é 100% idêntico ao que produzimos antes, mas sim, muito parecido (lembre-se do exemplo dos gêmeos). Ou seja, não somente é esperado que o que produzimos agora seja um pouco diferente do que produzimos antes, como mesmo o que foi produzido antes era um pouco diferente do que fora produzido um pouco antes. Assim, a comparação do “agora” com o “antes” é feita a partir da média dos valores. Ou seja, já que antes havia variação, calculamos a média dos valores de antes e comparamos o valor do que estamos produzindo agora: havendo causas comuns, é esperado que encontremos valores bem próximos do valor médio de antes, ao passo que, caso ocorram causas especiais, a média encontrada provavelmente será diferente e esse será nosso sinal de alerta.



Figura 6.6: Aviso e alerta. Os gráficos de controle servem para monitorar o andamento de processos, sinalizando de forma visual quando alguma anomalia for detectada. Quando isso acontece, os responsáveis pelo processo devem iniciar a investigação e análise, para compreender o que houve e decidir o que deve ser feito.

Fonte: <https://pt.freeimages.com/photo/traffic-light-1316690>

Desta forma, a representação gráfica encontrada nos gráficos de controle nos mostra o valor médio e os valores que achamos em nosso processo. Além disso, são mostrados, também, os limites, isto é, até quanto o afastamento do valor médio é “aceitável” (representado pelas variações devido às causas comuns) e a partir de que ponto seria um

alerta de que o processo está fora de controle, devido a causas especiais, como mostrado no exemplo a seguir.



Figura 6.7: Exemplo de gráfico de controle. Os gráficos de controle apresentam o valor médio, bem como os limites até onde as variações seriam consideradas aceitáveis, isto é, oriundas de causas comuns: LS – limite superior e LI – limite inferior. Repare que, no exemplo, há uma medida que ultrapassa o limite superior: isso seria um indício de existência de causa especial cuja razão deveria ser investigada, antes que maiores problemas ocorressem.

Mas, que medidas devem ser monitoradas e como são estabelecidos os limites? Para respondermos a estas perguntas, é necessário discutirmos alguns aspectos relevantes, referentes aos tipos de gráficos de controle, estatística, teste de hipóteses e teoria da amostragem.

Fundamentos estatísticos dos gráficos de controle

O controle estatístico do processo consiste em selecionar e avaliar uma quantidade significativa de itens produzidos que representem estatisticamente a produção. Como já discutido, as peças não serão idênticas, havendo variação nas medidas e, conseqüentemente, uma dispersão nos valores. A premissa (que deve posteriormente ser testada) é a de que a dispersão nos valores seja equivalente à de uma distribuição normal.

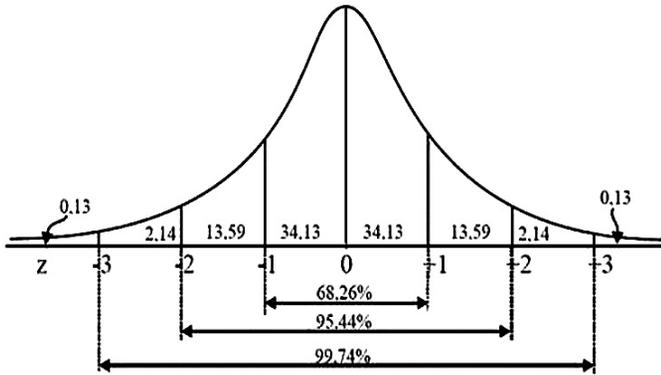


Figura 6.8: Curva normal. A representação de uma distribuição normal mostra uma concentração de valores ao redor do valor central (média): 68,26% das ocorrências dentro de uma faixa de ± 1 desvio-padrão; 95,44% na faixa de ± 2 desvios-padrões e 99,74% na faixa de ± 3 desvios-padrões. Desta forma, somente uma proporção muito pequena (aproximadamente 0,27%) das ocorrências estaria muito afastada do valor central, isto é, além dos ± 3 desvios-padrões.

Fonte: sondagens e estudos de opinião (2012).

O princípio fundamental dos gráficos de controle é que as variações de um processo que está sob controle, isto é, submetido tão-somente a causas normais, não variaria muito. Ou seja, as variações ficariam dentro de afastamentos de, no máximo, ± 3 desvios-padrões e, assim, esses seriam os limites de controle dos gráficos.

A lógica é a de que as medidas coletadas deveriam, ainda que variando, permanecer dentro de tais limites, ao passo que uma medida fora de tais limites seria um indício de uma causa especial, ou seja, algo “anormal” que causou tal variação no processo, afinal, lembre-se de que a probabilidade de termos valores fora dos limites é muito baixa (0,27%). Ribeiro e Caten (2012, p. 43) argumentam que, “caso apareça uma amostra fora dos limites de controle, a probabilidade dessa amostra pertencer a esse processo é muito pequena (0,27%), logo há uma forte evidência de que o processo mudou (média ou desvio) devido à presença de causas especiais”. Ainda de acordo com Ribeiro e Caten (2012, p. 10), as causas especiais “fazem com que o processo saia fora de seu padrão natural de operação, ou seja, provocam alterações na forma, tendência central ou variabilidade das características de qualidade”, como exemplificado na figura a seguir.

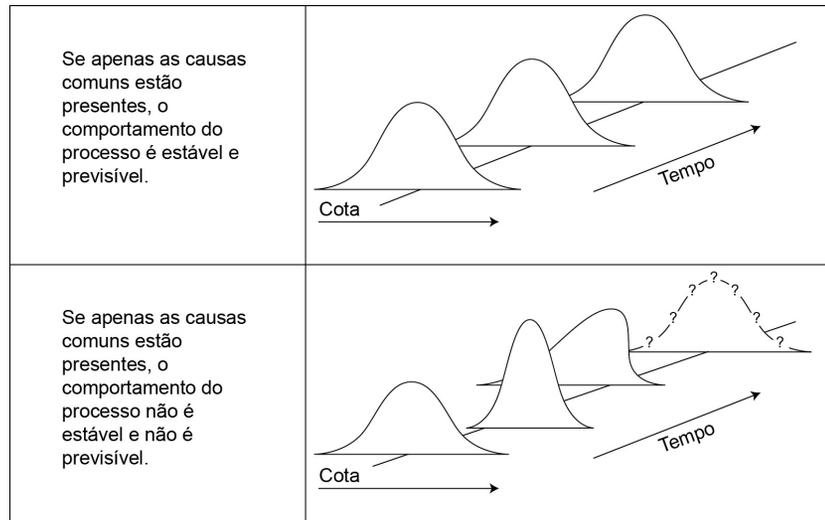


Figura 6.9: Distribuição de probabilidade de um processo estável versus instável. Em um processo estável, as variações nas medidas permanecem constantes, isto é, sujeitas somente às causas comuns, como mostrado na parte superior da figura. Já a influência de causas especiais pode fazer com que haja variação no parâmetro de localização (valor médio), dispersão (variabilidade dos dados em torno da tendência central), forma (simetria) ou qualquer combinação desses aspectos.

Fonte: Ribeiro e Caten (2012, p. 14).

A importância do controle estatístico está justamente na identificação da ocorrência de causas especiais, a partir do que se inicia um processo de análise e as ações de contenção e contramedidas para eliminá-las. De acordo com Montgomery e Runger (2009), uma das principais finalidades do controle estatístico do processo é detectar mudanças devidas a causas especiais, tomando rapidamente ações corretivas, de modo a minimizar a produção de itens não conformes.

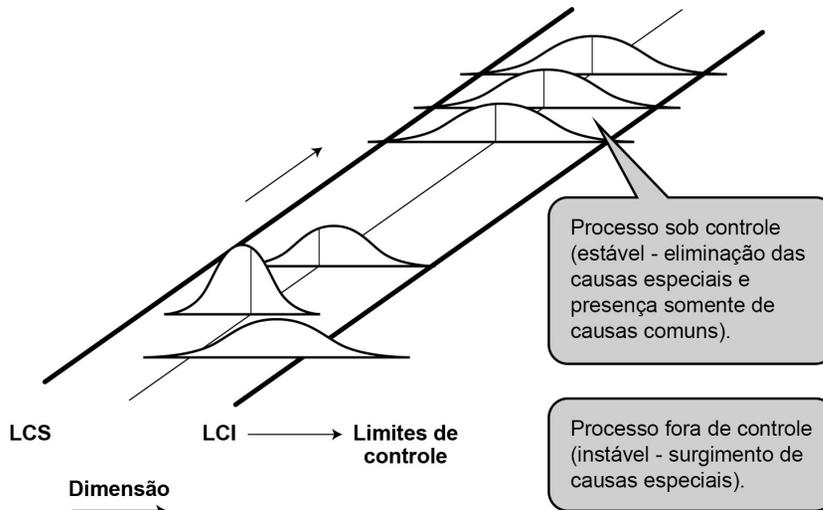


Figura 6.10: Processo instável versus processo estável. Mediante a identificação de ocorrência de causas especiais e atuação sobre estas, é possível eliminá-las e fazer com que o processo volte a estar sob controle.

Fonte: Ribeiro e Caten (2012, p. 13).

Outro aspecto a ser analisado é que, como não trabalhamos com inspeção 100%, mas sim com amostras no controle estatístico dos processos (vide Aulas 1 e 2), precisamos estabelecer o desvio-padrão para calcular os limites de controle do processo com base no desvio das amostras, mas que nos permitam avaliar a população das peças que são produzidas (afinal, essa é nossa preocupação: saber se há causas especiais atuando sobre o processo). Porém, antes de estudarmos como os limites são calculados, precisamos discutir os diferentes tipos de gráficos de controle, visto que cada um deles tem formas distintas de uso e, principalmente, de cálculo dos limites.

Tipos de gráficos de controle

Primeiramente, é importante lembrar que podemos lidar com duas famílias de gráficos de controle: os que lidam com variáveis contínuas (os chamados gráficos ou cartas de controle por variáveis) e os que lidam com variáveis discretas (os gráficos ou cartas por atributos). Uma forma simples para compreendermos as diferenças e os usos de tais tipos de gráfico é a de que os gráficos por variáveis lidam com “o que medimos”, ou seja, unidades quantitativas de medida (peso, altura, comprimento, etc.), ao passo que os gráficos por atributos são utilizados

para “o que contamos”, isto é característica da qualidade que pode estar, ou não, conforme as especificações (cor, tipo de acabamento, quantidade de defeitos de peças produzidas, etc.) (CHRISTO, 2017).

Assim, se voltarmos ao exemplo do lote de peças usinadas, podemos considerar as medidas como comprimento, diâmetro, espessura, etc. como passíveis de ser o foco de gráficos por variáveis: ao medirmos as peças, podemos encontrar valores fracionários, como dependendo da precisão de nosso processo de medição. Por exemplo, 10,2 mm, 10,21 mm, 10,208 mm, etc. (lembre-se de que estamos falando de variáveis contínuas). Por outro lado, se nosso foco for as medidas estarem dentro ou fora dos valores especificados ou as peças terem ou não algum dano superficial, etc., o que queremos saber é a quantidade (ou proporção) de peças defeituosas ou de defeitos encontrados, situação em que o mais apropriado é a utilização dos gráficos por atributos.

Vamos a um exemplo, tomando por base a peça mostrada a seguir.

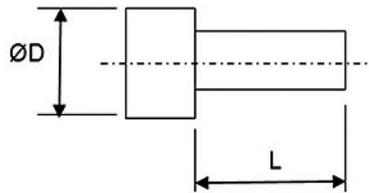


Figura 6.11: Peça-exemplo.

Foram produzidas cinco peças, cujas informações são mostradas a seguir.

Tabela 6.1: Informações sobre as cinco peças produzidas

Peça	ØD	L	Condições
Especificação (mm)	10,00 ±0,10	20,00 ±0,25	Sem danos
1	10,05	19,84	Ok
2	10,08	19,91	1 amassado
3	9,98	20,21	1 amassado e 2 pontos de ferrugem
4	10,12	20,28	Ok
5	9,96	20,03	Ok

Nesse exemplo, os gráficos por variáveis poderiam ser aplicados às medidas encontradas para $\bar{O}D$ e L, enquanto os gráficos por atributos poderiam ter como foco a quantidade de defeitos (ou não conformidades), quais sejam: diâmetro da peça 4, comprimento da peça 4, amassado da peça 2, amassado da peça 3 e ferrugem da peça 3, totalizando seis defeitos; ou a quantidade de peças defeituosas (ou não conformes), quais sejam, as peças 2 e 3 (total de duas).

Costa, Epprecht e Carpinetti (2016), bem como Christo (2017), apresentam uma lista dos gráficos de controle mais utilizados:

Cartas de controle de variáveis:

- cartas de controle para a média e a amplitude;
- carta de controle para o desvio-padrão;
- carta de controle para a mediana;
- carta de controle para valores individuais.

Cartas de controle de atributos:

- carta para % de não conforme;s
- carta np para número de não conformes;
- carta c para número de não conformidades;
- carta u para número de não conformidades por unidade.

Outras cartas (técnicas avançadas de controle):

- cartas para a soma acumulada (Cusum Chart);
- cartas para o monitoramento de médias móveis ponderadas/EWMA;
- carta para a média móvel exponencial;
- EVOP – Evolutionary Operation.

Na nossa disciplina, estudaremos os seguintes gráficos de controle:

Gráficos por variáveis (SAMOHYL, 2009):

- Gráfico \bar{X} -R: o mais utilizado, sendo o primeiro gráfico de controle lançado por Shewhart na década de 1920;

- Gráfico \bar{X} ou X_i : uma variante do gráfico \bar{X} -R, utilizado quando há taxa de produção muito baixa. Por isso, também é chamado de gráfico de controle para valores individuais;
- Gráfico \bar{X} -s: mais eficiente que o gráfico \bar{X} -R, sendo utilizado para grandes amostras.

Gráficos por atributos:

A seleção do tipo de gráfico por atributo (c, u, p ou np) leva em consideração se analisaremos a quantidade de defeitos ou de peças defeituosas, bem como o tamanho das amostras coletadas, conforme mostrado a seguir.

Tabela 6.2: Tipos de gráfico

Tipo de gráfico	O que é “contado”:	
	Defeitos (não conformidades)	Defeituosos (não conformes)
Tamanho das amostras		
=	c - quantidade de defeitos	np - quantidade de unidades defeituosas
= ou ≠	u - defeitos/unidade	p - proporção defeituosa

Gráfico \bar{X} -R

O que chamamos usualmente de Gráfico \bar{X} -R se trata, na verdade de dois gráficos: o Gráfico \bar{X} (também chamado de X-barra), que controla o valor médio; e o gráfico R, que controla a variação das medidas, isto é a amplitude (por isso, o nome “R”, do inglês *range*). Como cita Christo (2017, p. 8), “No acompanhamento de um aspecto quantitativo da qualidade, em geral, se controla tanto o valor médio daquele como sua variabilidade, através de gráficos separados”. Esta é a forma de controlarmos as possíveis variações da distribuição normal: o gráfico \bar{X} tem foco no parâmetro de localização (valor médio), enquanto o gráfico R monitora a dispersão (variabilidade dos dados em torno da tendência central) e, também, a forma e a simetria.

Um aspecto relevante a ser tratado é o da coleta de dados: como já discutido, trabalhamos com amostras da produção, isto é, não medimos

100% das peças produzidas. Mas há uma lógica na coleta da amostra: não selecionamos “uma peça” de tempos em tempos, mas sim “uma amostra”, composta de algumas peças (usualmente, de três a seis, até um máximo de nove), de tempos em tempos. Por exemplo, podemos coletar uma amostra de cinco peças a cada hora de produção (a discussão da frequência de coleta e tamanho da amostra será tratada nas aulas seguintes).

Há duas razões para tal procedimento: primeiramente, permite uma melhor visualização dos resultados e variações. Vamos compreender tal afirmação utilizando o exemplo apresentado por Samohyl (2009), referente à linha de produção de ração animal e o problema no enchimento do pacote de um quilo: muitas reclamações chegavam à empresa devido ao fato de os pacotes terem menos ração. Foram coletadas 25 amostras de cinco pacotes cada, cujos resultados (em gramas) são mostrados a seguir.

Tabela 6.3: Amostras de cinco pacotes de ração

Medidas	Amostras de hora em hora								
	1	2	3	4	5	6	7	8	9
1	1006,00	1009,69	1033,68	1051,89	963,31	1021,00	981,37	987,40	1030,14
2	1005,00	1000,00	1001,00	1031,00	993,69	1023,78	1010,28	994,03	1034,07
3	1006,04	985,31	1000,00	1027,00	1022,02	1020,00	990,56	990,67	973,01
4	1032,35	1001,00	1016,90	1026,36	990,05	1046,87	990,46	1025,03	994,89
5	1011,35	987,81	1033,01	1005,77	968,85	1009,24	954,43	1048,18	973,62
	10	11	12	13	14	15	16	17	18
1	1024,88	1003,00	999,00	1015,25	978,48	1021,71	1038,32	1050,00	1040,13
2	967,38	1031,54	1039,08	1020,00	995,55	1026,00	1013,77	1001,73	1025,99
3	1018,81	1017,65	1034,00	1010,00	989,48	1065,55	1009,32	1045,00	985,04
4	984,00	979,96	1001,00	1006,90	1006,95	1050,00	998,27	1023,59	1000,00
5	1035,11	1013,52	999,11	1011,67	1002,07	1041,78	980,34	1036,00	1011,00
	19	20	21	22	23	24	25		
1	1000,13	975,07	992,37	993,80	988,47	1049,23	1028,27		
2	1018,76	1036,42	962,40	1003,28	984,03	1035,78	997,39		
3	996,80	1020,49	1019,46	1005,36	982,06	999,00	1038,43		
4	1056,75	1012,66	1059,09	1022,28	988,64	1011,00	1017,86		
5	1024,60	1003,89	1045,39	971,96	978,32	1008,32	987,32		

Primeiramente, vamos criar um gráfico com as 125 medidas (25 amostras com 5 medidas cada), conforme mostrado a seguir.

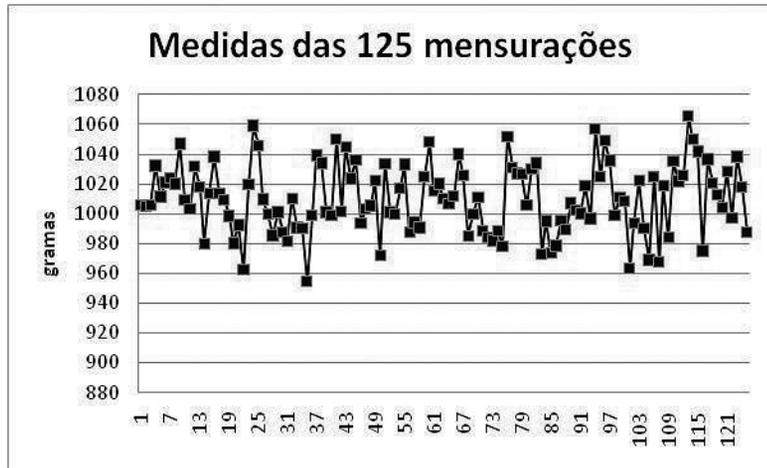


Figura 6.12: Gráfico gerado a partir das amostras de ração.

Você consegue identificar algum comportamento? Algum padrão? Difícil, não é mesmo? A impressão que temos é a de que os dados estão “embolados”, sobrepostos, dificultando qualquer percepção visual sobre o fenômeno estudado.

Mas, agora, vamos criar outro gráfico: ao invés das 125 medidas, vamos utilizar somente 25 (uma para cada amostra). Para tanto, calcularemos a média das cinco medidas em cada amostra e utilizaremos tais médias para compor o gráfico, que é mostrado a seguir, logo após a

tabela com os valores das médias.

Tabela 6.3: Médias das amostras

Médias das amostras								
1	2	3	4	5	6	7	8	9
1012,15	996,76	1016,92	1028,40	987,58	1024,18	985,42	1009,06	1001,15
10	11	12	13	14	15	16	17	18
1006,04	1009,13	1014,44	1012,76	994,51	1041,01	1008,00	1031,26	1012,43
19	20	21	22	23	24	25		
1019,41	1009,71	1015,74	999,34	984,30	1020,67	1013,85		



Figura 6.12: Gráfico gerado a partir da média das amostras.

E agora, ficou mais fácil? É possível perceber uma oscilação nos valores, seguida de uma breve tendência de subida, nova oscilação e uma tendência de redução? Pois bem, esse “agrupamento” é o que permite, como dito anteriormente, uma melhor visualização dos resultados e variações. No entanto, essa não é a principal razão para adotarmos tal procedimento: você lembra que nossa principal preocupação é a de conseguirmos identificar as variações devidas às causas especiais, enquanto não nos preocupamos com as causas comuns?

Pois bem, quando coletamos uma amostra, são peças “em sequência” do processo produtivo. Ou seja, todas deveriam ser iguais (na realidade, muito parecidas, com diferenças somente devido às causas comuns). Mas, quando coletamos uma amostra seguinte, já estamos falando de um intervalo razoável em que foram produzidas diversas peças. Ou seja, houve tempo para ocorrência de alguma causa especial.

Por exemplo, imagine que, após coletada uma amostra de cinco pacotes de ração, produzimos 1.000 outros pacotes até que fosse coletada nova amostra. Ao longo desse tempo, pode ter havido o entupimento do dosador, fazendo com que a alimentação fosse restrita e, consequentemente, que a quantidade de ração nos pacotes fosse abaixo do esperado: isso faria com que a média da próxima amostra ficasse bastante abaixo do esperado (possivelmente abaixo do limite inferior de controle do gráfico).

Outro exemplo: imagine que houve uma contaminação por água na ração, o que fez com que se formassem pelotas de ração aglutinada. Isso faria com que, ao invés de a ração fluir regularmente para os pacotes, ela se precipitasse de forma irregular: em alguns momentos pouca

ração seria alimentada, devido à dificuldade para fluir. Mas, o aumento do peso sobre o dosador faria com que o material cedesse e fluísse em maior volume e velocidade, o que faria com que houvesse um volume de ração superior ao esperado. Tais oscilações talvez não causassem uma variação significativa no valor médio. Mas, com certeza, aumentaria a dispersão dos valores, isto é a amplitude das medidas (lembre-se de que utilizamos dois gráficos de controle: o \bar{X} para o valor médio e o R para amplitude).

Desta forma, a coleta de amostras, com determinada quantidade de medidas cada uma, e um intervalo entre as amostras é o mecanismo que permite que consigamos identificar os indícios de ocorrência de causas especiais (entre as amostras) nos gráficos de controle. Vamos utilizar o exemplo da ração para construir nosso gráfico de controle e verificar se, com base nos dados coletados, temos um processo sob controle ou não. Como você viu, a construção do gráfico prevê a colocação do valor médio e dos limites superior e inferior. No caso do gráfico \bar{X} , o valor médio é calculado como a média dos valores médios de cada amostra. Ou seja, calculamos 25 médias (as que foram calculadas para traçar o gráfico das médias das amostras) e calculamos a média dos 25 valores (por isso damos o nome de “média das médias”), como mostrado na equação a seguir.

$$\bar{\bar{X}} = \frac{\bar{X}_1 + \bar{X}_2 + \dots + \bar{X}_k}{K}$$

Sendo:

$\bar{\bar{X}}$ = média das médias

$\bar{X}_1, \bar{X}_2, \dots, \bar{X}_k$ = médias das K amostras

K = quantidade de amostras

Calculado o valor da média das médias, encontramos o valor de 1.010,17 gramas: esse será o valor médio a ser utilizado no gráfico de controle \bar{X} . O próximo passo é estabelecer os valores dos limites superior e inferior do gráfico, isto é, afastamentos de três desvios-padrões “para cima” e três desvios-padrões “abaixo” da média das médias, de forma a compreender 99,73% dos valores de médias amostrais na distribuição normal (SAMOHYL, 2009; RIBEIRO; CATEN, 2012).

Como estamos lidando com amostras, e não com a população, o desvio-padrão para se converter em erro padrão é dividido pelo \sqrt{n} , onde n é o tamanho da amostra, como mostrado na equação a seguir.

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

De forma a evitarmos cálculos complexos, podemos fazer uso de tabelas que nos indicam diretamente os fatores para cartas de controle, isto é, fatores para cálculo dos limites de controle, a partir do tamanho da amostra. Especificamente, no caso do gráfico \bar{X} , o fator de limite A_2 é o que necessitamos, visto que os limites podem ser calculados diretamente pelas equações mostradas a seguir.

$$LCS = \bar{X} + A_2 \bar{R}$$

$$LCI = \bar{X} - A_2 \bar{R}$$

Sendo:

LCS = limite de controle superior

A_2 = fator de limite

\bar{R} = amplitude média

LCI = limite de controle inferior

Para cálculo da amplitude média, seguimos a mesma lógica do cálculo da média das médias: calcula-se a amplitude de cada média e, em seguida, calcula-se a média desses valores, como mostrado na equação a seguir.

$$\bar{R} = \frac{R_1 + R_2 + \dots + R_K}{K}$$

Sendo:

R_1, R_2, \dots, R_K as amplitudes de cada uma das K amostras.

A seguir você encontra as amplitudes de cada uma das 25 amostras de nosso exemplo dos pacotes de ração.

Tabela 6.4: Amplitudes das amostras

Amplitudes das amostras								
1	2	3	4	5	6	7	8	9
27,35	24,38	33,68	46,12	58,71	37,63	55,85	60,78	61,06
10	11	12	13	14	15	16	17	18
67,73	51,58	40,08	13,1	28,47	43,84	57,98	48,27	55,09
19	20	21	22	23	24	25		
59,95	61,35	96,69	50,32	10,32	50,23	51,113		

Calculando o valor da média das amplitudes, encontramos $\bar{R} = 47,67$ gramas. Para concluirmos o cálculo dos limites de controle, precisamos, agora, identificar tão-somente o valor do fator A_2 . Para isso, utilizamos a tabela a seguir.

Tabela 6.5: Tamanho das amostras para o fator A_2

Tamanho da amostra (n)	A_2
2	1,881
3	1,023
4	0,729
5	0,577
6	0,483
7	0,419
8	0,373
9	0,337
10	0,308
11	0,285
12	0,266
13	0,249
14	0,235
15	0,223
16	0,212
17	0,203
18	0,194
19	0,187

20	0,180
21	0,173
22	0,167
23	0,162
24	0,157
25	0,153

Fonte: Adaptado de Siqueira (1997, p. 128).

Como o tamanho da amostra é “5”, temos $A_2 = 0,577$. Podemos, assim, efetuar os cálculos dos limites:

$$LCS = 1.010,17 + 0,577 \times 47,67 = 1.037,68 \text{ gramas e}$$

$$LCI = 1.010,17 - 0,577 \times 47,67 = 982,66 \text{ gramas.}$$

Traçamos, assim, o nosso gráfico:

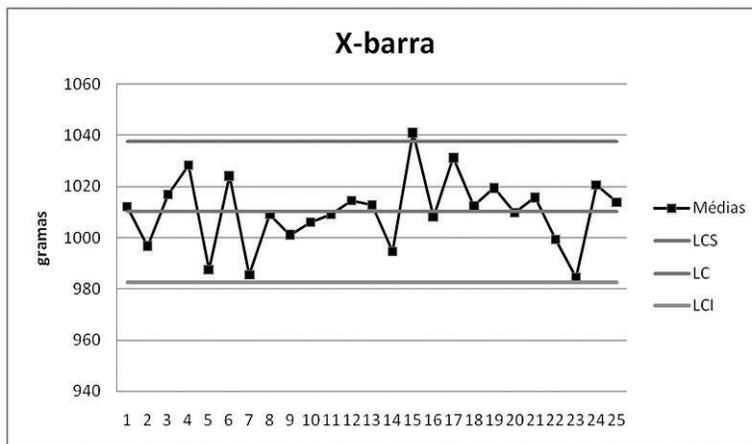


Figura 6.13: Gráfico gerado a partir das médias das amostras e seus limites de controle.

Como você pode observar, um dos pontos se encontra fora dos limites de controle: a amostra de número 15, com um valor médio de 1.041,01 gramas, está acima do limite de controle superior (1.037,68 gramas), caracterizando, portanto, que o processo não está sob controle. Uma vez que tal medida tivesse sido identificada, deveria ser iniciado de imediato um processo de investigação, buscando identificar a causa-raiz de tal problema. Para tanto, poderiam ser utilizadas ferramentas antes

estudadas, como, por exemplo, o diagrama de causa e efeito (vide Aula 5) e o ciclo PDCA (vide Aula 2).

Mas, essa não é a única análise feita: lembre-se de que há ainda o gráfico R. Para este, segue-se a mesma lógica, sendo o valor médio estabelecido como a média das amplitudes e os limites estabelecidos pelas seguintes fórmulas:

$$LCS = D_4 \bar{R}$$

$$LCI = D_3 \bar{R}$$

Sendo:

D_3 e D_4 os fatores para limites de controle para amplitude. Os valores de tais fatores são mostrados na tabela a seguir.

Tabela 6.6: Fatores para limites de controle para amplitude

Tamanho da amostra (n)	D_3	D_4
2	0	3,269
3	0	2,574
4	0	2,282
5	0	2,114
6	0	2,004
7	0,076	1,924
8	0,136	1,864
9	0,184	1,816
10	0,223	1,777
11	0,256	1,744
12	0,284	1,716
13	0,308	1,692
14	0,328	1,672
15	0,347	1,653
16	0,363	1,637
17	0,378	1,622
18	0,391	1,609
19	0,403	1,597
20	0,414	1,586
21	0,425	1,575

22	0,434	1,566
23	0,443	1,557
24	0,452	1,548
25	0,460	1,540

Fonte: Adaptado de Siqueira (1997, p. 128).

Como o tamanho da amostra é “5”, temos que $D_3 = 0$ e $D_4 = 2,114$.
 Desta forma, temos:

$$LCS = 2,114 \times 47,67 = 100,77 \text{ gramas e}$$

$$LCI = 0 \times 47,67 = 0.$$

Construímos, então, o gráfico:

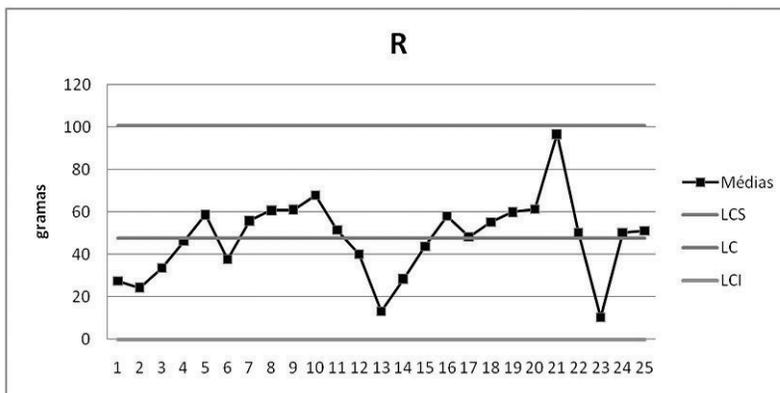


Figura 6.14: Gráfico gerado com base nos fatores para limites de controle para amplitude.

Neste caso, como você pode observar, não há pontos fora dos limites de controle. Entretanto, isso não significa que está tudo ok, afinal, o gráfico \bar{X} já havia nos indicado que o processo estava fora de controle. Um processo só é considerado sob controle, quando não há pontos fora dos limites, tanto no gráfico \bar{X} quanto no gráfico R.

Na verdade, Costa, Epprecht e Carpinetti (2016) recomendam que a construção dos gráficos se inicie pelo gráfico R, visto que este é afetado somente pela dispersão, enquanto o gráfico \bar{X} é afetado tanto pela dispersão (lembre-se que a fórmula dos limites toma por base a média das amplitudes) quanto pelo deslocamento da média. Assim sendo, o

pressuposto é o de que só faria sentido desenvolvermos um gráfico \bar{X} após nos certificarmos de que o processo não está sujeito a causas especiais que afetem a dispersão, o que é verificado pelo gráfico R.

É importante destacar que os limites estabelecidos não são fixos: conforme Samohyl (2009), os gráficos de controle devem ser atualizados periodicamente, com novos limites calculados: uma vez por mês é uma prática comum, ou quando mudanças substanciais no processo (mova máquina ou material, por exemplo) ocorrerem.

No entanto, a lógica da coleta de amostras com múltiplas medidas têm, eventualmente, algumas limitações. Por exemplo, quando o volume de produção é muito baixo (ex: poucas unidades por dia); quando as medições são demoradas e/ou muito caras (por exemplo, ao exigirem a parada de produção, testes destrutivos, etc.); ou quando o processo tem características muito homogêneas, que variam muito lentamente (como em digestores químicos) (RIBEIRO; CATEN, 2012). Nesses casos, faz-se necessário recorrer aos gráficos X_i .

Gráfico X_i

Quando não é viável a coleta de determinada quantidade de medidas em uma amostra e/ou quando as possíveis variações entre as amostras ocorrem muito lentamente (por exemplo, referente ao pH de um banho químico), ou ainda, quando o processo de coleta e análise das amostras é demorado e de alto custo, pode ser necessário e conveniente utilizar um tipo de gráfico de controle que possa contornar tais barreiras: trata-se do gráfico X_i (ou X individual), que trabalha em conjunto com o gráfico de amplitude móvel (AM).

A lógica destes gráficos é a de que cada amostra contém somente uma medida e a base comparativa de uma medida é a medida anterior. Vamos ver como isso funciona, tomando o exemplo apresentado por Samohyl (2009) de uma sequência de temperaturas de uma composição química.

Tabela 6.7: Sequência de temperaturas de uma composição química

Amostra	Valores	Amplitude móvel
1	95,43	4,42
2	99,85	0,24

3	100,09	1,64
4	101,73	0,45
5	102,18	3,81
6	98,37	2,84
7	101,21	4,95
8	96,26	2,64
9	98,90	1,98
10	96,92	1,22
11	95,70	0,65
12	95,05	2,76
13	97,81	0,03
14	97,84	5,25
15	103,09	7,91
16	95,18	2,43
17	97,61	0,39
18	97,22	4,56
19	101,78	1,54
20	103,32	1,29
21	102,03	1,99
22	104,02	5,34
23	98,68	0,30
24	98,38	
Média	99,11	2,55

Os valores da coluna “Amplitude móvel” foram calculados pela diferença entre valores subsequentes. Por exemplo, a diferença entre 95,43 (amostra 1) e 99,85 (amostra 2) é 4,42; a diferença entre 99,85 (amostra 2) e 100,09 (amostra 3) é 0,24, e assim sucessivamente. Com isso, temos 23 medidas de amplitude, para as 24 medidas coletadas.

Calculamos, então, a média dos valores (\bar{X}) e das amplitudes (\bar{R}) (observe que os valores de amplitude são sempre positivos, pois o que queremos mensurar é a amplitude, isto é, a diferença entre os valores, independentemente de qual deles é maior). A partir de tais valores, podemos calcular os limites dos gráficos, a partir das seguintes equações:

$$LC = \bar{X} \pm 3 \frac{\bar{R}}{d_2}$$

$$LCS = D_4 \bar{R}$$

$$LCI = D_3 \bar{R}$$

Sendo:

d_2 o fator para valor central.

Quanto aos valores de d_2 , D_3 e D_4 , ainda que dependentes do tamanho da amostra, temos uma peculiaridade para tais gráficos: como a amplitude móvel é calculada como a diferença entre cada par de leituras sucessivas, o tamanho de amostra é sempre $n = 2$ (RIBEIRO; CATEN, 2012). Assim, temos:

Tamanho da amostra (n)	D_3	D_4
2	0	3,269

$$E d_2 = 1,128$$

Podemos, com isso, calcular os limites e traçar os gráficos para esse exemplo de uso do Gráfico \bar{X}_i . Para os valores, temos:

$$LCS = 99,11 + 3 \times 2,55 / 1,128 = 105,89 \text{ e}$$

$$LCI = 99,11 - 3 \times 2,55 / 1,128 = 92,33.$$

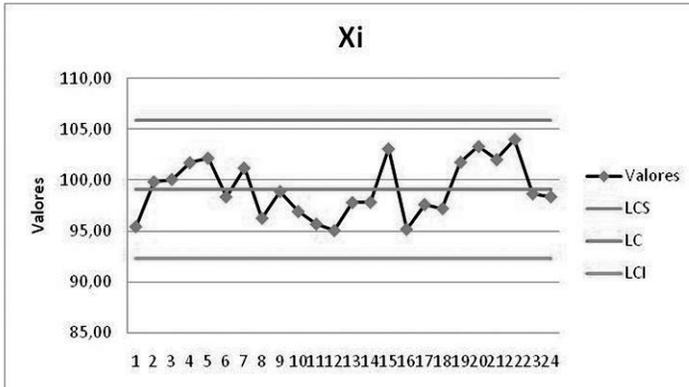


Figura 6.15: Gráfico Xi.

E para a dispersão (amplitude), temos:

$$LCS = 3,269 \times 2,55 = 8,33 \text{ e}$$

$$LCI = 0 \times 2,55 = 0.$$

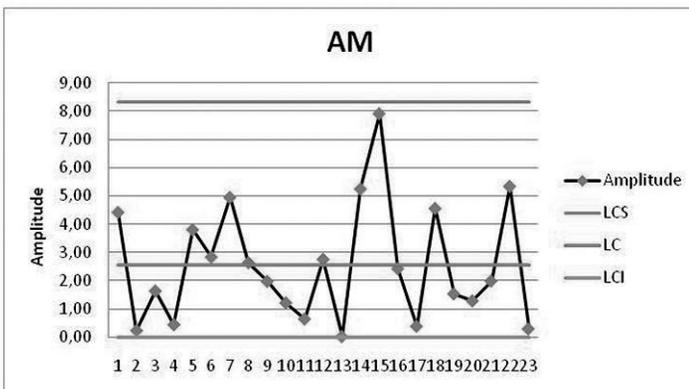


Figura 6.16: Gráfico AM.

Como você pode observar, não há pontos fora dos limites de controle em nenhum dos dois gráficos, caracterizando, portanto, que o processo está sob controle, isto é, submetido somente a causas normais.

Atividade

Atende aos objetivos 1 e 2

A empresa Controle Total está preocupada com as reclamações que recebe de seus clientes sobre dificuldades no envase do seu produto XYZ. Há a suspeita que o processo produtivo possa não estar garantindo que a viscosidade do XYZ se mantenha dentro das especificações.

Foram coletadas amostras diárias de viscosidade de bateladas químicas durante 30 dias e nenhuma delas apresentou valores de viscosidade inferior a 4,0 Pa.s ou superior a 8,0 Pa.s, que são as especificações do produto, como mostrado a seguir.

Amostra	Pa.s
1	6,0
2	6,5
3	6,0
4	5,0
5	6,2
6	4,5
7	6,0
8	5,4
9	5,0
10	6,5
11	6,1
12	5,6
13	5,5
14	4,5
15	4,2
16	4,7
17	7,8
18	4,5
19	6,0
20	7,0

21	6,0
22	6,0
23	5,5
24	6,5
25	6,0
26	6,5
27	5,0
28	6,5
29	6,0
30	6,5

Fonte: Adaptado de Ribeiro e Caten (2012).

Concluiu-se, assim, que o processo estava sob controle e que deve haver alguma outra razão para as reclamações.

Com base nas informações, pergunta-se:

- a) A análise feita para avaliar se o processo está sob controle foi adequada?
- b) Você recomendaria o uso de alguma outra forma de análise?
- c) É correto afirmar que o processo está sob controle?

Resposta comentada

A análise feita considerou tão-somente atributos, isto é, verificou se as amostras eram conformes ou não conformes. Como a viscosidade é uma variável contínua, essa não foi uma forma adequada para avaliar se o processo está sob controle ou não: o que se sabe é somente que nenhuma das amostras foi rejeitada, mas isso não é suficiente para afirmar que o processo está sob controle.

Por tratar-se de uma variável contínua e ser um processo químico, isto é, com características homogêneas (que variam muito lentamente), o mais adequado é que seja utilizado o gráfico de controle \bar{X}_i .

Calculando a amplitude móvel e a média dos valores e da amplitude:

Amostra	Pa.s	A. Móvel
1	6,0	0,5
2	6,5	0,5
3	6,0	1,0
4	5,0	1,2
5	6,2	1,7
6	4,5	1,5
7	6,0	0,6
8	5,4	0,4
9	5,0	1,5
10	6,5	0,4
11	6,1	0,5
12	5,6	0,1
13	5,5	1,0
14	4,5	0,3
15	4,2	0,5
16	4,7	3,1
17	7,8	3,3
18	4,5	1,5
19	6,0	1,0
20	7,0	1,0
21	6,0	0,0
22	6,0	0,5
23	5,5	1,0
24	6,5	0,5
25	6,0	0,5
26	6,5	1,5
27	5,0	1,5
28	6,5	0,5
29	6,0	0,5
30	6,5	
Média	5,78	0,97

Calculando os limites do Gráfico \bar{X}_i . Para os valores, temos:

$$LCS = 5,78 + 3 \times 0,97 / 1,128 = 8,36 \text{ e}$$

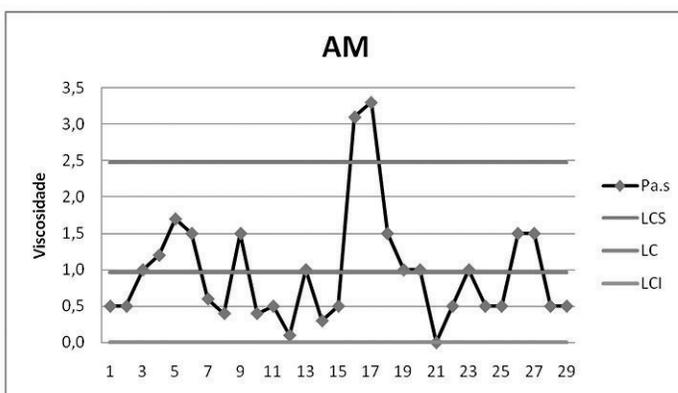
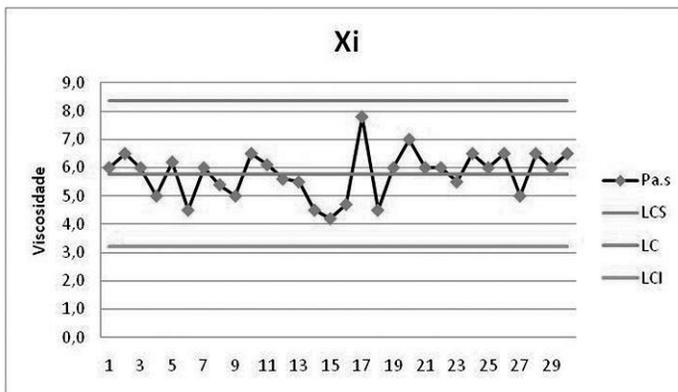
$$LCI = 5,78 - 3 \times 0,97 / 1,128 = 3,21.$$

E para a dispersão (amplitude), temos:

$$LCS = 0,97 \times 2,55 = 2,47; \text{ e}$$

$$LCI = 0 \times 2,55 = 0.$$

Traçando os respectivos gráficos:



Como você pode perceber, ainda que o gráfico dos valores não aponte qualquer anomalia, isto é, não há qualquer ponto fora dos limites de controle, o mesmo não pode ser dito sobre o gráfico de dispersão: há

dois pontos acima do limite de controle superior, indicando a existência de causas especiais sobre o processo, que não está, portanto, sob controle. A causa de tais problemas precisa ser analisada e investigada, de forma a melhorar o processo produtivo.

Conclusão

A mais sofisticada das ferramentas da qualidade – o gráfico de controle – apresenta uma grande potencialidade para garantir a qualidade nos processos produtivos. Diferentemente de outras ferramentas, o gráfico de controle permite a identificação de problemas antes que eles causem danos e defeitos. Desta forma, é possível uma antecipação de ações de contenção dos problemas, isto é, agir sobre os problemas antes que eles, de fato ocorram.

Isso é possível mediante o fato de que os gráficos de controle não monitoram a adequação dos resultados, mas sim sua consistência. Algo do tipo “se está tudo bem e nada muda, é provável que tudo continue bem”, ao passo que, ao ser detectada alguma mudança (na forma de variação além dos limites), isso é sinal de que alguma coisa mudou no processo e, conseqüentemente, o que estava bem antes, pode trazer problemas em breve. Associados a outras ferramentas da qualidade, os gráficos de controle auxiliam a blindar as empresas contra problemas diversos e garantir seus bons resultados em termos de desempenho e custos.

Resumo

Para o controle e a melhoria da qualidade, é comum a utilização de ferramentas, quais sejam:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de Pareto;

- diagrama de causa e efeito;
- histograma;
- gráficos de controle.

Os gráficos de controle se prestam a monitorar aspectos de qualidade dos produtos e processos, por meio da verificação de amostras coletadas de tempos em tempos. Mediante estudos estatísticos, é possível inferir se as variações encontradas são consideradas aceitáveis, isto é, se ocorrem tão-somente devido a causas normais, como variações de temperatura, vibração, etc., ou se outros fatores não previstos (as chamadas causas especiais) afetam o processo, o que indicaria que este estaria fora de controle e, conseqüentemente, passível de gerar produtos não conformes.

Há gráficos de controle utilizados para variáveis contínuas (como peso, comprimento, temperatura, etc.), que funcionam “em pares”, isto é, monitorando os valores médios encontrados e sua dispersão ao redor do valor central; e há os gráficos por atributos (isto é, defeitos, não conformidades, etc.), em que se avaliam as quantidades ou proporções de defeitos ou unidades defeituosas.

Uma característica comum a todos os gráficos de controle é o estabelecimento de limites (superior e inferior), que delimitam as faixas de valores que caracterizariam a variação devido a causas comuns e, fora dos limites, a ocorrência de causas especiais.

Leituras recomendadas

REIS, Marcelo Menezes. *Um modelo para o ensino do controle estatístico da qualidade*, 2001. 380 f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2001. Disponível em: <https://repositorio.ufsc.br/handle/123456789/79748>. Acesso em: 9 jan. 2019.

Informação sobre a próxima aula

Na próxima aula, continuaremos os estudos dos gráficos de controle, com foco nos gráficos \bar{X} e s ; média e desvio-padrão.

Referências

CHRISTO, E. S. Aula 6 – *Ferramentas para o controle da qualidade*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 6), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=8>. Acesso em: 25 fev. 2019.

COSTA, Antônio Fernando Branco; EPPRECHT, Eugenio Kahn; CARPINETTI, Luiz César Ribeiro. *Controle estatístico de qualidade*. 2. ed. São Paulo: Atlas, 2016.

FUJITA, H. et al . Contribuição ao estudo da retificação abrasiva de materiais cerâmicos. *Cerâmica*, São Paulo, v. 52, n. 324, p. 269-275, dez. 2006. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0366-69132006000400010&lng=en&nrm=iso. Acesso em: 29 dez. 2018.

MONTGOMERY, D. C.; RUNGER, G. C. *Estatística aplicada e probabilidade para engenheiros*. 4. ed. Rio de Janeiro: LTC, 2009.

RIBEIRO, José Luis Duarte; CATEN, Carla Schwengber ten. *Controle estatístico do processo: cartas de controle para variáveis, cartas de controle para atributos, função de perda quadrática, análise de sistemas de medição*. Série monográfica Qualidade. Porto Alegre: FEENG/UFRGS – Fundação Empresa-Escola de Engenharia da UFRGS – Universidade Federal do Rio Grande do Sul, 2012.

ROCHA, Henrique Martins. *Fatores críticos de sucesso do start up de veículos e a qualidade (CMMI) do desenvolvimento de produtos no Sul Fluminense*, 2005, 353f. Dissertação (Mestrado em Sistemas de Gestão) – Universidade Federal Fluminense, Niterói, 2005.

SAMOHYL, R. W. *Controle estatístico de qualidade*. Rio de Janeiro: Campus, 2009.

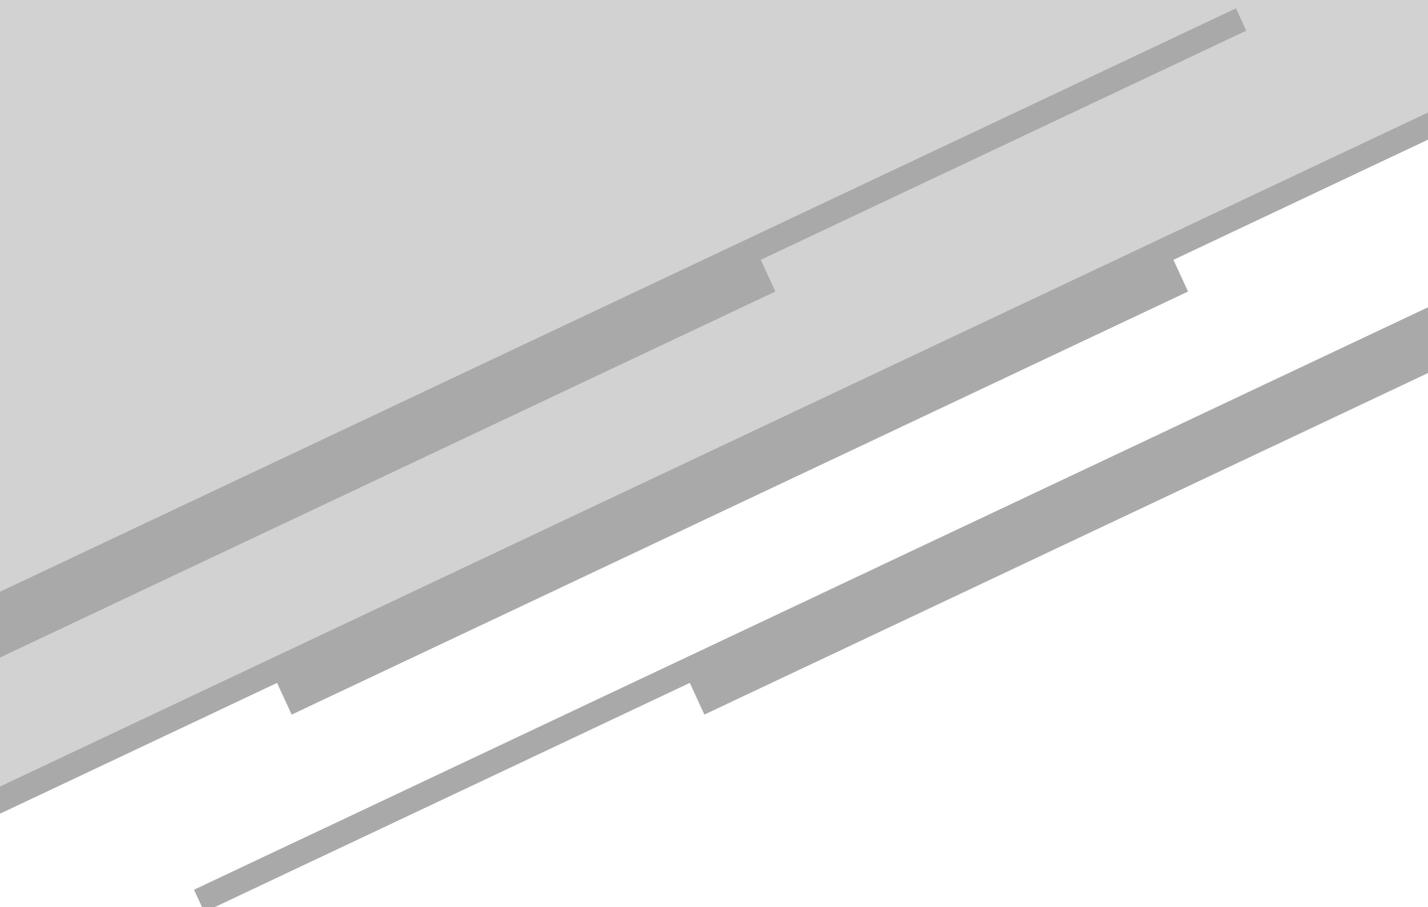
SIQUEIRA, Luiz Gustavo. *Controle estatístico do processo*. São Paulo: Pioneira, 1997.

SONDAGENS E ESTUDOS DE OPINIÃO. *Estatística descritiva*. Escola Superior de Educação do Politécnico de Coimbra, 25 nov. 2012. Disponível em: <https://sondagenseestudosdeopiniao.wordpress.com/estatistica/estatistica-descritiva/>. Acesso em: 3 jan. 2019.

TRIBUNAL REGIONAL ELEITORAL DO DISTRITO FEDERAL (TRE-DF). *Gêmeos idênticos, digitais diferentes*. Disponível em: <http://www.tre-df.jus.br/imprensa/noticias-tre-df/2013/Agosto/gemeos-identicos-digitais-diferentes>. Acesso em: 28 dez 2018.

Aula 7

Ferramentas para o controle da qualidade:
gráfico de controle (continuação)



Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. saber como utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. conhecer o gráfico de controle ou cartas de controle para variáveis e para atributo, que representa uma das ferramentas mais utilizadas no controle da qualidade.

Pré-requisitos

Funções estatísticas e distribuição normal, ciclo PDCA, estratificação, folha de verificação, histograma, causas comuns e causas especiais, gráfico \bar{X} -R, conteúdos trabalhados nas aulas anteriores.

Introdução

O avanço tecnológico permitiu que alcançássemos patamares de produção e produtividade muito superiores aos obtidos quando da Revolução Industrial. No entanto, alta velocidade e altos volumes de produção trazem o risco de produzirmos grandes quantidades de produtos inadequados, caso existam falhas no processo produtivo. Assim, junto à evolução das tecnologias dos processos produtivos, fez-se necessária a evolução dos métodos de controle da qualidade, em especial, dos métodos estatísticos da qualidade, que têm nos gráficos de controle sua ferramenta mais sofisticada.

Um dos avanços na construção de tais gráficos foi a possibilidade de torná-los mais precisos, utilizando cálculos estatísticos mais complexos, em especial, o cálculo do desvio-padrão, enquanto os gráficos originais se limitavam a utilizar a amplitude dos valores das amostras. É isso que você estudará aqui: você continuará estudando o gráfico de controle, em um formato mais sofisticado e poderoso que o modelo desenvolvido inicialmente por Shewhart, e verá como este é utilizado para o controle da qualidade. Bons estudos!

O conceito do controle estatístico da qualidade, calcado nos gráficos de controle estatístico, desenvolvidos na década de 1920, foram um marco na história da qualidade. A mera inspeção e separação do que era “bom” ou “ruim” deu lugar a um monitoramento contínuo e detectivo de variações que poderiam ser indício de problemas no processo produtivo (vide Aula 1).

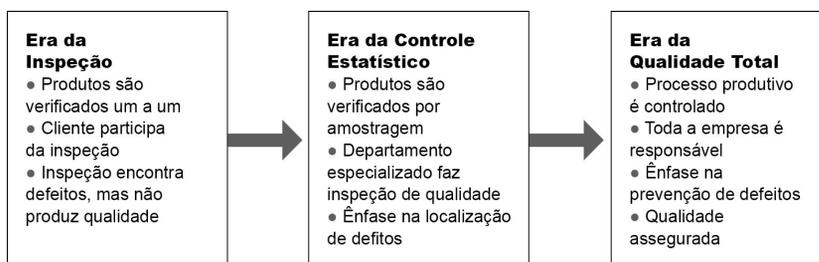


Figura 7.1: Evolução da qualidade: a história da qualidade pode ser resumida em três fases: (i) inspeção com ações reativas aos problemas; (ii) preocupação detectiva, mediante o uso do controle estatístico, e (iii) abordagem ativa, visando a excelência em todos os processos.

Fonte: Adaptado de Affonso (2018, p. 44).

Chão de fábrica

É a expressão que representa o ambiente de produção em operações industriais, ou seja, onde a atividade-fim de uma indústria acontece. Diferencia-se, assim, dos ambientes de gestão e apoio (ex: escritórios).

Mas isso só foi possível no ambiente industrial (e, posteriormente, para outros tipos de atividades econômicas) pelo fato de os gráficos de controle poderem ser utilizados no “**chão de fábrica**”, isto é, poderem ser elaborados e, principalmente, analisados, pelos operários.

Os conceitos estatísticos utilizados nos gráficos de controle já eram conhecidos antes de Shewhart, mas, devido à complexidade matemática envolvida em seus cálculos, era praticamente impossível serem utilizados por operadores de produção e ficavam limitados ao uso por engenheiros. Mas a ida de Deming ao Japão (vide Aula 1) auxiliou a quebrar tal barreira, ao disseminar a importância do envolvimento de todos na qualidade, desde a alta administração ao chão de fábrica.

E, nesse sentido, o gráfico \bar{X} -R trazia uma grande vantagem: seus cálculos eram simples, podendo ser executados pelos operadores, com um mínimo de treinamento. Os cálculos dos elementos dos gráficos ocorriam a partir da identificação das amplitudes das amostras e, a partir daí, o mero uso das quatro operações (soma e divisão, para cálculo das médias, e soma, subtração e multiplicação, para cálculo dos limites), como você viu na Aula 6.

A facilidade de tais cálculos, junto à facilidade de interpretação dos gráficos na identificação de alguma possível forma de descontrole do processo, isto é, mediante a observação visual da existência de pontos fora dos limites, fez com que estes fossem rapidamente adotados no ambiente fabril do Japão, expandindo-se posteriormente não somente para outras partes do mundo, mas também para outras áreas de atividade.

Maiores volumes de produção e, principalmente, exigências de maior qualidade nos processos produtivos fizeram com que surgisse a necessidade de gráficos de controle mais precisos e “potentes”, isto é, com maior capacidade de detecção. Nesse sentido, é importante lembrar que a amplitude de uma amostra trabalha com apenas duas medidas: o maior valor e o menor valor e, conseqüentemente, a mensuração da dispersão dos dados é limitada.

Vamos compreender isso, tomando por base o exemplo de duas amostras:

Tabela 7.1: Comparação entre duas amostras

Medidas	Valores	
	Amostra 1	Amostra 2
1	52	52
2	55	53
3	62	51
4	51	55
5	69	69
6	66	70
7	73	54
8	66	73
9	58	71
10	66	72

Uma observação atenta mostra que a amplitude das duas amostras é a mesma (22), pois o maior valor e o menor valor em ambas são idênticos (respectivamente, 73 e 51). Podemos, então, afirmar que a dispersão nas amostras é a mesma? O que você acha?

Vamos colocar os valores na forma gráfica, para auxiliar na análise e resposta, sendo o primeiro gráfico correspondente aos valores da Amostra 1 e o segundo, aos da Amostra 2:

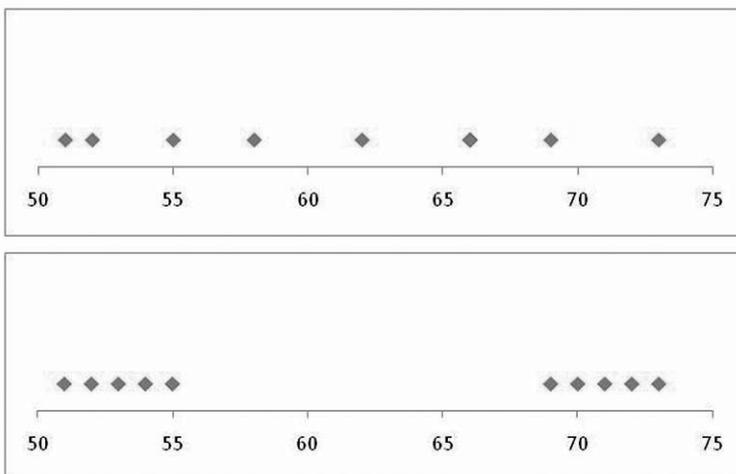


Figura 7.1: (a) Valores da amostra 1; (b) Valores da amostra 2.

Repare que, se pensarmos em um valor médio (por exemplo, a média da amostra 1 é 61,8, e a da amostra 2 é 62; ou a mediana da amostra 1 é 64, e da amostra 2 é 62), percebemos que os valores no segundo gráfico estão mais afastados desse valor médio do que os valores do primeiro gráfico, caracterizando, portanto, uma maior dispersão. Além da análise visual, podemos calcular a variância e os desvios-padrão nas duas amostras, de forma a mensurar de forma mais apropriada a dispersão de cada uma. Encontramos, nesse caso:

Tabela 7.2: Variância e desvio-padrão das duas amostras

Medidas	Valores	
	Amostra 1	Amostra 2
Variância	55,96	92,22
Desvio-padrão	7,48	9,60

Infer-se, assim, que a amplitude não consegue capturar a medida de dispersão dos valores com tanta precisão quanto o desvio padrão. Na realidade, o exemplo com dez medidas em cada amostra apresenta um caso limítrofe: de acordo com Montgomery e Runge (2009) e Christo (2017), para amostras com até dez medidas, há pouca diferença entre o uso da amplitude ou do desvio padrão para análise da dispersão em gráficos de controle. No entanto, para valores superiores a este, é recomendado que seja utilizado o gráfico de controle \bar{X} -s, ao invés do gráfico \bar{X} -R.

O “s” em questão, do gráfico de controle \bar{X} -s, refere-se ao desvio-padrão da amostra. Lembre-se de que o “s” é utilizado para amostra, enquanto σ é usado para a população. A seguir, você encontra um resumo dos símbolos estatísticos mais relevantes.

Quadro 7.1: Símbolos estatísticos mais relevantes

Elementos	Símbolo	
	Amostra	População
Variância	s^2	σ^2
Desvio-padrão	s	σ
Média	\bar{x}	μ
Tamanho	n	N

Gráficos de Controle \bar{X} -s

A disseminação dos computadores por todos os ramos de atividades permitiu que operações que ficavam limitadas a laboratórios pudessem ser efetuadas praticamente em qualquer local. Isso inclui as linhas de produção, nas quais é comum serem utilizados computadores e sistemas computadorizados em atividades diversas, não somente por supervisores, mas, também, por operadores de produção.



Figura 7.2: Sistema computadorizado utilizado na área de produção. Se os computadores inicialmente ficavam restritos a laboratórios específicos, sua massificação fez com que eles se tornassem parte de nosso dia a dia, presentes em nossas casas, escritórios, fábricas, etc.

Fonte: <https://pt.freeimages.com/photo/factory-1441533>

Com isso, a eventual dificuldade de utilização do desvio-padrão como medida de dispersão, devido à maior complexidade dos cálculos quando comparados com os da amplitude, para o uso nos gráficos de controle, deixou de ser significativa. Afinal, com a mesma facilidade que podemos utilizar uma planilha Excel para calcular as médias das amostras, as médias das médias das amostras, as médias das amplitudes das amostras, podemos, também, calcular os desvios-padrões das amostras.

Veja a seguir algumas dessas funções (MICROSOFT, s.d.):

- Função DESVPADA: estima o desvio-padrão com base em uma amostra, inclusive números, textos e valores lógicos;
- Função DESVPADPA: calcula o desvio-padrão com base na população total, inclusive números, textos e valores lógicos;
- Função MÁXIMO: retorna o valor máximo em uma lista de argumentos;
- Função MÉDIA: retorna a média dos argumentos;
- Função MED: retorna a mediana dos números indicados;
- Função MÍNIMO: retorna o valor mínimo em uma lista de argumentos;
- Função VARA: estima a variação com base em uma amostra, inclusive números, textos e valores lógicos;
- Função VARPA: calcula a variação com base na população total, inclusive números, textos e valores lógicos.

Observação: a sintaxe das funções pode variar, dependendo da versão do Excel utilizada. Desta forma, é recomendado que você acesse as fórmulas estatísticas (como mostrado na figura a seguir) e identifique as fórmulas que são adequadas à análise que deseja.

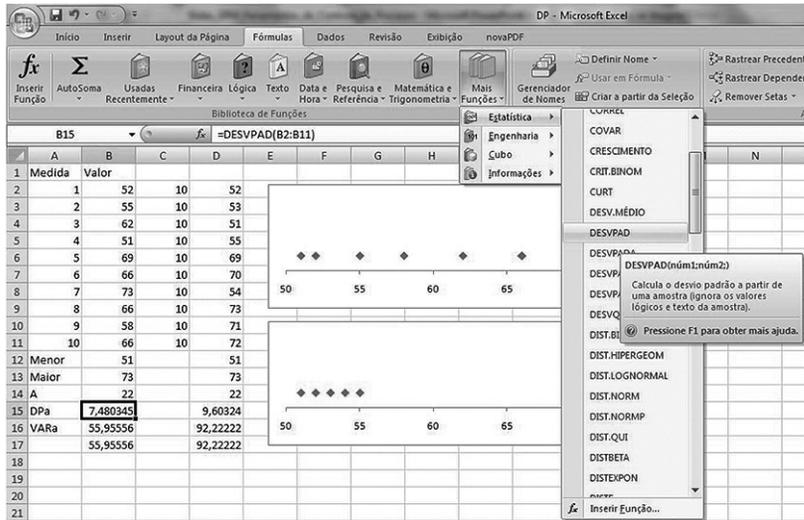


Figura 7.3: Acesso às funções estatísticas do Excel. Colocando o cursor sobre as funções, é possível visualizar a descrição da função em si e de sua sintaxe. No exemplo, vemos a função para calcular o desvio-padrão de uma amostra, na versão 2010 do Excel.

Dentro deste contexto, a vantagem que o gráfico \bar{X} -R tinha sobre o gráfico \bar{X} -s, em termos de facilidade nos cálculos, deixa de existir: além do próprio Excel, softwares estatísticos, como, por exemplo, R, Minitab, SPSS e STATISTICA (dentre outros), permitem o fácil e rápido processamento dos dados para análises estatísticas.



Se você quiser saber mais sobre os softwares citados, acesse os links abaixo:

R – <https://www.r-project.org/>

MINITAB – <http://www.minitab.com/pt-br/>

SPSS – <https://www.ibm.com/analytics/br/pt/technology/spss/>

STATISTICA – <http://www.statsoft.com/Products/STATISTICA-Features>

Conforme o caso, o monitoramento do desvio-padrão (s) pode ser mais apropriado que o monitoramento da amplitude. O desvio-padrão é um indicador mais eficiente da variabilidade, principalmente para amostras grandes. Tipicamente, recomenda-se o uso da carta s quando: a) os dados forem coletados por computador e for fácil de implementar uma rotina de cálculo, b) os processos forem sofisticados, controlados por especialistas e c) as amostras forem grandes (subgrupos de tamanho $n > 10$) (RIBEIRO; CATEN, 2012, p. 67).

Assim sendo, o uso do gráfico \bar{X} - s se torna cada vez mais comum, em especial quando lidamos com altos volumes de produção e processos automatizados.



Figura 7.4: Medindo peças. Processos produtivos repetitivos, com alto volume de produção e, em especial, que produzam peças e componentes com medidas críticas para o bom funcionamento do produto final, são processos candidatos a serem monitorados por meio do gráfico de controle \bar{X} - s .

Fonte: <https://pixabay.com/pt/medida-calliper-ferramenta-precis%C3%A3o-2090115/>

A exemplo do gráfico \bar{X} - R , o que chamamos de gráfico \bar{X} - s , é, na realidade, um par de gráficos, que são usados em conjunto: o \bar{X} , para os valores e o s para a dispersão dos valores. Também, a forma de análise é exatamente a mesma: valores dentro dos limites nos levam a crer que o processo está sob controle (também é comum encontramos a expressão “em controle”), sem causas especiais (somente causas normais), enquanto pontos fora dos limites seriam indício da ocorrência de causas especiais (vide Aula 6). Desta forma, as equações referentes ao gráfico \bar{X} seriam:

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

$$\bar{\bar{X}} = \frac{\bar{X}_1 + \bar{X}_2 + \dots + \bar{X}_m}{m}$$

$$LSC = \bar{\bar{X}} - (A * \bar{S})$$

$$LC = \bar{\bar{X}}$$

$$LIC = \bar{\bar{X}} + (A * \bar{S})$$

Sendo:

LSC = limite superior de controle (obs: comumente denominado, também, limite de controle superior – LCS);

LC = limite (ou linha) central;

LIC = limite inferior de controle (obs: comumente denominado, também, limite de controle inferior – LCI);

\bar{X} = média de cada amostra;

$\bar{\bar{X}}$ = média das médias;

1, 2, ... m = médias das m amostras;

m = quantidade de amostras;

$\bar{X}_1, \bar{X}_2, \dots, \bar{X}_m$ = desvio-padrão médio das m amostras;

A_3 = fator de limite.



Atenção: como os desvios-padrões a serem utilizados para calcular o desvio-padrão médio se referem às amostras, o cálculo (caso feito manualmente) deve considerar a seguinte fórmula, que é diferente da fórmula usada para calcular o desvio-padrão da população (repare no denominador $n - 1$):

$$s = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n-1}}$$

Mas, se tanto no gráfico \bar{X} -R quanto no gráfico \bar{X} -s, o \bar{X} se refere ao valor médio, por que as fórmulas são diferentes para o cálculo dos limites? Isso acontece porque os limites de controle são calculados com base na dispersão dos valores e, desta forma, como o gráfico \bar{X} -R toma a amplitude das amostras como medida de dispersão, enquanto o gráfico \bar{X} -s utiliza o desvio-padrão, tanto as medidas de dispersão, como os fatores de limite são diferentes (A_2 para gráfico \bar{X} -R e A_3 para o gráfico \bar{X} -s). A seguir, você encontra o valor do fator A_3 , em função do tamanho da amostra.

Tabela 7.3: Valor do fator A_3 , em função do tamanho da amostra

Tamanho da amostra (n)	A_3
2	2,659
3	1,954
4	1,628
5	1,427
6	1,287
7	1,182
8	1,099
9	1,032
10	0,975
11	0,927
12	0,886
13	0,850
14	0,817
15	0,789
16	0,763
17	0,747
18	0,718
19	0,698
20	0,680
21	0,663
22	0,619
23	0,633
24	0,619
25	0,606

Fonte: Adaptado de Siqueira (1997, p. 128).

Já para o gráfico s , as equações são as que seguem:

$$LSC = B_4 * \bar{S}$$

$$LC = \bar{S}$$

$$LIC = B_3 * \bar{S}$$

Sendo:

B_3 e B_4 = fatores de limite, os quais são apresentados a seguir.

Tabela 7.4: Valor do fator B_3 e B_4 , em função do tamanho da amostra

Tamanho da amostra (n)	B_3	B_4
2	0	3,266
3	0	2,568
4	0	2,266
5	0	2,089
6	0,030	1,970
7	0,118	1,882
8	0,185	1,815
9	0,239	1,761
10	0,284	1,716
11	0,322	1,678
12	0,354	1,646
13	0,381	1,619
14	0,407	1,593
15	0,428	1,572
16	0,448	1,552
17	0,466	1,691
18	0,482	1,518
19	0,496	1,504
20	0,510	1,490
21	0,523	1,477
22	0,535	1,465

23	0,545	1,455
24	0,555	1,445
25	0,564	1,436

Fonte: adaptado de Siqueira (1997, p. 128) e Montgomery (2001, p. 761).

Para aplicação, vamos utilizar como base o mesmo exercício da Aula 6, em que Samohyl (2009) relata o problema dos pacotes de ração, cujos dados coletados são replicados a seguir. Lembre-se de que, devido ao fato de o tamanho da amostra ser relativamente pequeno, não é esperado que se encontrem diferenças significativas entre os resultados dos gráficos \bar{X} -s para os gráficos \bar{X} -R.

Tabela 7.5: Medidas das amostras de hora em hora

Medidas	AMOSTRAS (HORA EM HORA)								
	1	2	3	4	5	6	7	8	9
1	1006,00	1009,69	1033,68	1051,89	963,31	1021,00	981,37	987,40	1030,14
2	1005,00	1000,00	1001,00	1031,00	993,69	1023,78	1010,28	994,03	1034,07
3	1006,04	985,31	1000,00	1027,00	1022,02	1020,00	990,56	990,67	973,01
4	1032,35	1001,00	1016,90	1026,36	990,05	1046,87	990,46	1025,03	994,89
5	1011,35	987,81	1033,01	1005,77	968,85	1009,24	954,43	1048,18	973,62
	10	11	12	13	14	15	16	17	18
1	1024,88	1003,00	999,00	1015,25	978,48	1021,71	1038,32	1050,00	1040,13
2	967,38	1031,54	1039,08	1020,00	995,55	1026,00	1013,77	1001,73	1025,99
3	1018,81	1017,65	1034,00	1010,00	989,48	1065,55	1009,32	1045,00	985,04
4	984,00	979,96	1001,00	1006,90	1006,95	1050,00	998,27	1023,59	1000,00
5	1035,11	1013,52	999,11	1011,67	1002,07	1041,78	980,34	1036,00	1011,00
	19	20	21	22	23	24	25		
1	1000,13	975,07	992,37	993,80	988,47	1049,23	1028,27		
2	1018,76	1036,42	962,40	1003,28	984,03	1035,78	997,39		
3	996,80	1020,49	1019,46	1005,36	982,06	999,00	1038,43		
4	1056,75	1012,66	1059,09	1022,28	988,64	1011,00	1017,86		
5	1024,60	1003,89	1045,39	971,96	978,32	1008,32	987,32		

No mesmo exercício, calculamos as médias das amostras, que também são replicadas a seguir, bem como a média das médias (1.010,17 gramas), o qual será utilizado no gráfico de controle \bar{X} .

Tabela 7.6: Médias das amostras

Médias das amostras								
1	2	3	4	5	6	7	8	9
1012,15	996,76	1016,92	1028,40	987,58	1024,18	985,42	1009,06	1001,15
10	11	12	13	14	15	16	17	18
1006,04	1009,13	1014,44	1012,76	994,51	1041,01	1008,00	1031,26	1012,43
19	20	21	22	23	24	25		
1019,41	1009,71	1015,74	999,34	984,30	1020,67	1013,85		

Mas, apesar do \bar{X} permanecer o mesmo, os limites precisam ser recalculados, como discutimos anteriormente. Calculamos, então, o desvio-padrão de cada uma das 25 amostras. Os valores são apresentados na tabela a seguir.

Tabela 7.7: Desvio-padrão das amostras

Desvio-padrão das amostras								
1	2	3	4	5	6	7	8	9
11,56	13,84	19,25	21,30	39,25	10,09	20,29	20,27	19,32
10	11	12	13	14	15	16	17	18
18,43	16,43	26,55	5,04	21,55	4,39	16,41	29,64	11,13
19	20	21	22	23	24	25		
24,00	20,97	23,29	28,91	17,90	22,76	21,23		

A partir de tais valores, podemos calcular o desvio-padrão médio ($\bar{S} = 19,35$), o que nos permite, assim, calcular os limites (como o tamanho da amostra = 5, o $A_3 = 1,427$).

$$LCS = 1010,17 + 1,427 \times 19,35 = 1.037,78 \text{ gramas e}$$

$$LCI = 1010,17 - 1,427 \times 19,35 = 982,56 \text{ gramas.}$$

Observação: como esperado, os limites ficaram bem próximos dos calculados na Aula 6, referente ao gráfico \bar{X} -R, que foram LCS = 1.037,68 gramas; e LCI = 982,66 gramas.

Ainda que Montgomery e Runger (2009) e Costa, Epprecht e Carpinetti (2016) recomendem que a construção dos gráficos se inicie pelo gráfico referente à dispersão (R ou s) (vide Aula 6), para efeitos didáticos e por saber que, para pequenas amostras, não é esperada diferença significativa entre os gráficos \bar{X} -R e \bar{X} -s, construiremos primeiramente o gráfico \bar{X} .

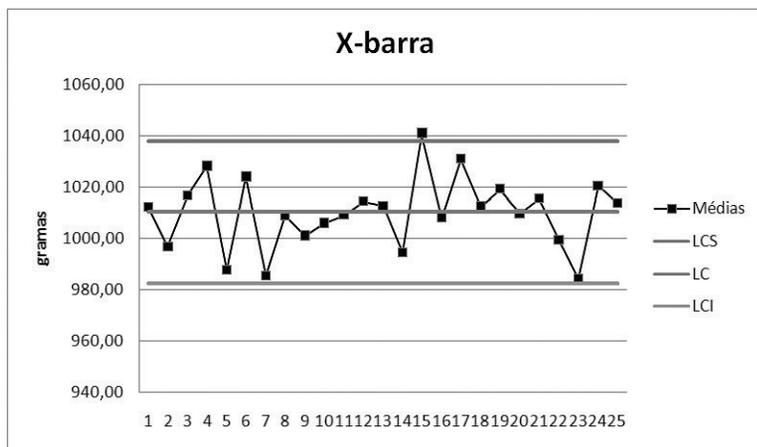


Figura 7.5: Gráfico \bar{X} .

Obviamente, o gráfico é semelhante ao do \bar{X} -R (vide Aula 6), visto que os valores são tão próximos que não é possível identificar visualmente as diferenças entre eles. Vamos, agora, construir o gráfico s. Com o tamanho da amostra = 5, temos que $B_3 = 0$ e $B_4 = 2,089$. Assim...

$$LCS = 2,089 \times 19,35 = 40,42 \text{ gramas e}$$

$$LCI = 0 \times 19,35 = 0.$$

A título de comparação, os valores para o gráfico \bar{X} -R (vide Aula 6) foram: LCS = 100,77 e LCI = 0. Há, portanto, uma diferença significativa nos valores. Mas, é importante lembrar que, ainda que ambos meçam a dispersão, são medidas completamente diferentes: a amplitude é, obviamente, sempre superior ao desvio-padrão, visto que ela mensura o

afastamento entre o maior e o menor valor, enquanto o desvio-padrão representa um valor médio dos afastamentos do valor central.

Construímos, então, o gráfico correspondente, que é mostrado a seguir.

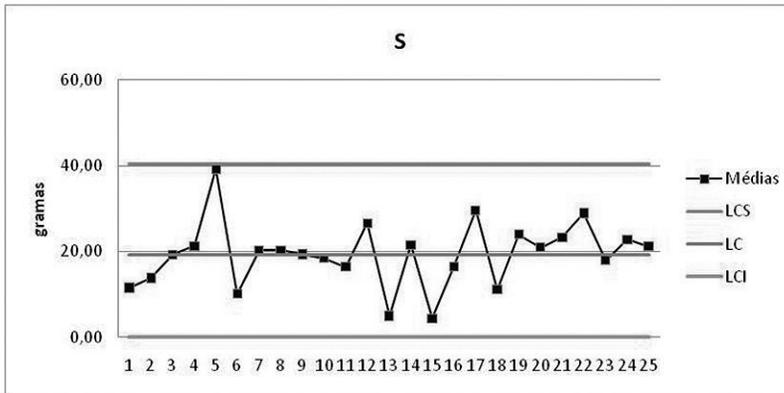
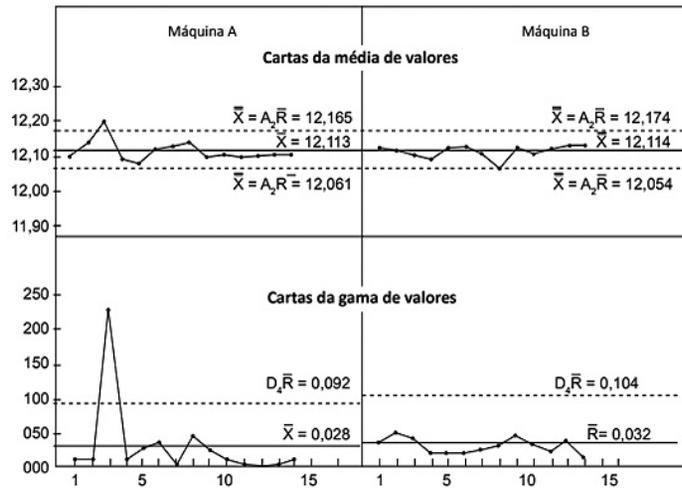


Figura 7.6: Gráfico s.

Você pode observar que não há pontos fora dos limites. No entanto, isso não significa que o processo está sob controle, afinal, lembre-se de que o gráfico \bar{X} não mostrou o mesmo resultado e as análises devem ser feitas, sempre, em conjunto, isto é, os dois gráficos devem ser gerados e analisados. Veja, por exemplo, uma questão do Enade de 2017 de Engenharia de Produção (INEP, 2017, p. 22), que apresenta tal situação, em gráficos de controle \bar{X} -R.

Questão 19: As indústrias farmacêuticas necessitam de rigoroso controle de qualidade de seus processos produtivos, em razão da precisão dos princípios ativos presentes nos fármacos e na regularidade (posologia) requerida pelos tratamentos de saúde. A respeito desse procedimento, são apresentadas, a seguir, as cartas de controle do processo de enchimento de ampolas com comprimidos, cuja alimentação é feita por duas máquinas A e B, em uma indústria farmacêutica.

Cartas de Controle para a média e gama (amplitude) das máquinas de enchimento A e B



LIMA, A. A. N. et al. Aplicação do controle estatístico de processo na indústria farmacêutica. Revista de ciências farmacêuticas básica e aplicada, v. 27, n. 3, p. 184, 2006 (adaptado).

Analisando as cartas de controle das máquinas A e B, apresentadas na figura, conclui-se que, para reduzir a variância do processo de enchimento de ampolas com comprimidos, deve-se:

- ampliar os limites das cartas de controle de ambas as máquinas para diminuir a variação da massa de enchimento das ampolas.
- adicionar uma operação posterior de inspeção 100%, após o processamento da máquina A, de forma a garantir a precisão dos princípios ativos.
- manter o processo produtivo de ambas as máquinas como está, uma vez que as cartas da média de valores apresentam variação insignificante.
- atuar no processo da máquina A para se reduzir a variação da massa de enchimento e garantir a precisão dos princípios ativos.
- aumentar o tamanho das amostras do processo da máquina A, a fim de reduzir a amplitude da massa de enchimento das ampolas com valores superior a 100.

Limites provisórios nos gráficos de controle

Como você viu, a lógica dos gráficos de controle não é a de identificar peças conformes ou não conformes, mas sim, apurar se as medidas do que está sendo produzido se mantêm próximas do que fora produzido

anteriormente. Importante destacar, também, que o fato de não encontrarmos pontos fora dos limites em determinado processo não significa que temos o processo sob controle indefinidamente: precisamos, de tempos em tempos (por exemplo, um mês é uma boa prática, caso não tenha havido qualquer mudança no processo, nos operadores, nas matérias-primas ou na manutenção nas máquinas) recalculamos os limites de controle. Ou seja, em um processo estável, utilizamos os valores do mês 1 para calcular os limites de controle para monitorar o processo no mês 2; os valores do mês 2 para calcularmos os limites do mês 3, e assim sucessivamente.



Atenção: se temos processos sem indicação de causas especiais, não é recomendável que façamos qualquer intervenção no processo, sob o risco de estarmos inserindo uma causa especial. Ou, como defendido por Shewhart, o criador dos gráficos de controle, “se o processo estiver em controle, evite ajustes desnecessários, que só tendem a aumentar a sua variabilidade” (COSTA, EPPRECHT; CARPINETTI, 2016, p. 45).

Mas, e quando iniciamos um processo (ou o modificamos) e não temos uma base anterior para comparação? Isto é, como obter os valores médios das medidas e da dispersão deles? Nesse caso, precisamos estabelecer os chamados “valores provisórios”, os quais, basicamente, seguem os mesmos passos lógicos de cálculo já vistos: coletamos medidas em determinado número de amostras e, a partir delas, calculamos os valores médios e limites, os quais são utilizados para monitorar o desempenho do processo daí para frente. Ou seja, os dados coletados inicialmente servem para estabelecer os limites de controle dos dados que se seguirão.

E se tais resultados indicarem que o processo está fora de controle, isto é, se apresentar pontos fora dos limites, o que devemos fazer? Reflita um pouco sobre isso... Bem, o que é um processo “sob controle”? É um processo que está submetido somente a causas comuns, certo?

[vide Aula 6]. Assim, há variação entre as medidas, mas são variações aceitáveis e previsíveis, ao passo que o processo “fora de controle”, está sujeito a causas especiais e, conseqüentemente, apresenta variações de medidas atípicas e substanciais. Desta forma, se coletamos medidas de um processo e ele apresenta pontos fora dos limites, inferimos que ele está submetido a causas especiais e, por isso, não podemos utilizá-lo como base para monitorar o processo daí para frente.

Para tanto, precisaríamos trabalhar com dados de um processo que está submetido tão somente a causas comuns, certo? Pois bem, essa lógica é que nos permite tomar uma decisão que a princípio parece inusitada: simplesmente descartamos as amostras que estão fora dos limites de controle! Ao fazermos isso, estaremos deixando de considerar os efeitos das causas especiais já identificadas, de tal forma que nos restem somente os efeitos das causas comuns.

Observe que isso *não* é o que devemos fazer quando encontramos pontos fora dos limites nos gráficos de controle que estão sendo utilizados para monitorar a produção: nesses casos, como você já estudou, devemos investigar a causa e tomar as medidas necessárias sobre o processo (vide Aula 06). E, a propósito, dependendo das ações tomadas, como ajuste ou manutenção da máquina, regulagem de ferramentas, etc., por estarmos fazendo mudanças no processo, é recomendado que façamos nova coleta de amostras.

O descarte das amostras com pontos fora dos limites (ou seja, os que ocorrem devido às causas especiais) visa simular um processo submetido tão-somente a causas comuns, a partir do qual podemos estabelecer os limites de controle para monitorar o que será produzido. Então, é só uma questão de descartar a(s) amostra(s) e usar os limites calculados? Não! Após descartar os pontos fora dos limites, precisamos recalcular os novos limites, para um processo que, hipoteticamente, deveria estar submetido somente a causas comuns. Isso é necessário, pois os pontos fora dos limites distorcem os cálculos dos valores, o que poderia nos levar a ter gráficos de controle excessivamente “benevolentes”, isto é, com limites excessivamente “abertos”. Vamos compreender como isso ocorreria, tomando como exemplo 10 medidas hipotéticas, como mostrado a seguir.

Tabela 7.8: Medidas hipotéticas

Medida	1	2	3	4	5	6	7	8	9	10
Valor	1029	1026	1029	1025	1027	1025	1098	1024	1024	1028

Uma rápida análise visual já é suficiente para você perceber que a medida “7” está muito diferente das demais. Vamos supor, então, que ela é um ponto além do limite superior, isto é uma indicação de uma causa especial. Se nós não a descartássemos para podermos calcular os limites provisórios dos gráficos de controle, teríamos os seguintes valores para trabalhar:

$$\bar{X} = 1.033,50;$$

$$R = 74 \text{ e}$$

$$s = 22,74.$$

No entanto, vamos descartar a citada amostra e recalcular tais valores:

Tabela 7.9: Medidas hipotéticas sem a 7

Medida	1	2	3	4	5	6	8	9	10
Valor	1029	1026	1029	1025	1027	1025	1024	1024	1028

$$\bar{X} = 1.026,33;$$

$$R = 5 \text{ e}$$

$$s = 2.$$

Repare como o descarte da amostra “7” alterou a média das médias dos valores (como você sabe, valores extremos afetam significativamente a média), mas principalmente as medidas de dispersão R e s (respectivamente, quase 15 e mais de 11 vezes superiores ao que deveriam ser), que são a base para cálculo dos limites superior e inferior, de acordo com as equações que você aprendeu. Ou seja, se estivéssemos construindo um gráfico -R, não somente o valor estaria deslocado, mas o afastamento dos limites de controle seria superior ao que deveria ser e, conseqüentemente, poderíamos aprovar pontos que deveriam estar fora

dos limites, como mostrado na figura a seguir.

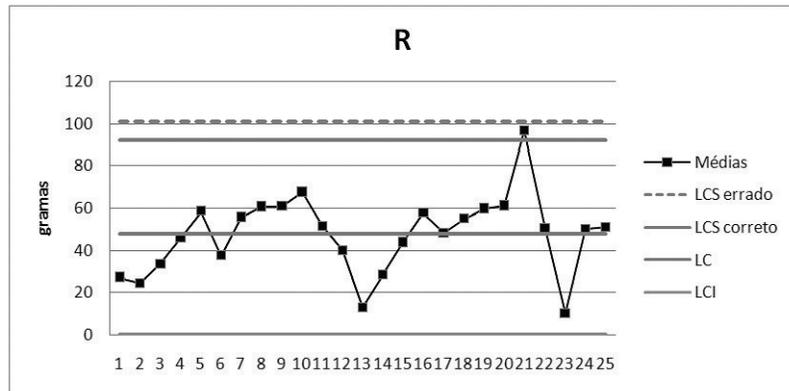


Figura 7.7: Sem a exclusão da amostra 7, poderíamos aprovar pontos fora dos limites.

Vamos, então, aproveitar o exemplo dos pacotes de ração, que apresentou um ponto fora do limite no gráfico, para compreender quais seriam os passos para estabelecer os limites provisórios, supondo que as amostras coletadas tivessem tal finalidade. Analisando os dados, vemos que a média da amostra “15” foi a que se posicionou acima do LCS: 1.040,01 gramas, para um limite de 1.037,78 gramas. Vamos, então, descartar a mesma e refazer os cálculos. Importante destacar que diferentes autores propõem abordagens distintas para o descarte de amostras. Ribeiro e Caten (2012, p. 39), por exemplo, determinam que, “caso haja pontos fora dos limites de controle, deve-se retirar as amostras correspondentes e recalculando os limites de controle”, ao passo que Costa, Epprecht e Carpinetti (2016, p. 57) optam por não recalculando os limites do gráfico de dispersão (R ou s), se este não tiver pontos fora dos limites, “pois o processo já tinha sido considerado estável com respeito à dispersão”.

Adotaremos uma visão mais conservadora, descartando a amostra e recalculando todos os limites. Temos, assim:

Tabela 7.10: Média das amostras, com a exclusão da 15

Médias das amostras								
1	2	3	4	5	6	7	8	9
1012,15	996,76	1016,92	1028,40	987,58	1024,18	985,42	1009,06	1001,15
10	11	12	13	14	16	17	18	19
1006,04	1009,13	1014,44	1012,76	994,51	1008,00	1031,26	1012,43	1019,41
20	21	22	23	24	25			
1009,71	1015,74	999,34	984,30	1020,67	1013,85			

Tabela 7.11: Desvio-padrão das amostras, com a exclusão da 15

Desvio-padrão das amostras								
1	2	3	4	5	6	7	8	9
11,56	13,84	19,25	21,30	39,25	10,09	20,29	20,27	19,32
10	11	12	13	14	16	17	18	19
18,43	16,43	26,55	5,04	21,55	16,41	29,64	11,13	24,00
20	21	22	23	24	25			
20,97	23,29	28,91	17,90	22,76	21,23			

Com a nova configuração, após descartada a amostra “15”, temos:

$$\bar{X} = 1.008,88;$$

$$s = 19,98.$$

E, a partir desses valores, calculamos os limites dos gráficos:

Para \bar{X} : LCS = 1.037,39 gramas; e LCI = 980,38 gramas (os valores anteriores eram respectivamente 1.037,78 e 982,56 gramas).

Para s : LCS = 41,73 gramas; e LCI = 0 (os valores anteriores eram, respectivamente, 40,42 e 0 gramas).

Calculados os limites, são traçados os gráficos \bar{X} -s, mostrados a seguir.

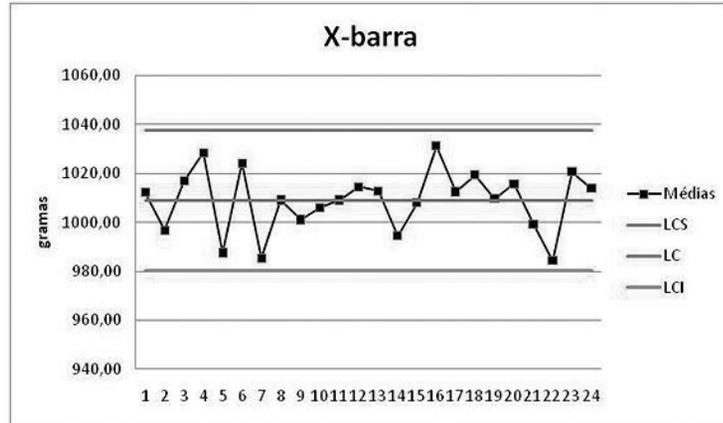


Figura 7.8: Gráfico \bar{X} .

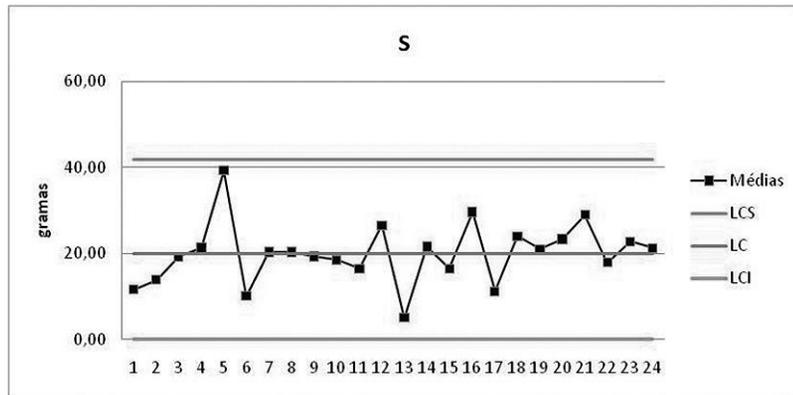


Figura 7.9: Gráficos \bar{X} -s.

Observe que não há pontos fora dos limites de controle. Ou seja, não há indicações de causas especiais e, desta forma, os limites estabelecidos poderiam ser utilizados como limites provisórios para monitorar o processo. Mas, e se tivéssemos, novamente, encontrado pontos fora dos novos limites? (Acredite: isso pode acontecer...) Neste caso, o processo se repetiria, isto é, descartaríamos a(s) amostra(s) nessa situação e recalculariamos os limites de controle, construindo, uma vez mais, os gráficos para análise.

Na verdade, faríamos isso tantas vezes quantas fossem necessárias, até termos somente gráficos sem indicação de causas especiais. Obviamente, há um limite para isso: não podemos reduzir tanto a quantidade de amostras a ponto de inviabilizar a análise. Se isso acontecer, pode-se

“prolongar o período de coleta até obter pontos suficientes” (COSTA; EPPRECHT; CARPINETTI, 2016, p. 52) ou, em caso extremo, chegar-se à conclusão que o processo não é estável, requerendo uma investigação para compreender as causas. Para isso, podem ser utilizadas outras ferramentas da qualidade, como, por exemplo, a folha de verificação, o diagrama de causa e efeito, etc.

Coleta de amostras para gráficos de controle

Tendo em mente que a função dos gráficos de controle é prover um alerta prévio sobre potenciais problemas, o que é feito pela detecção de variações nos resultados dos processos. Fica claro, então, que quanto mais cedo o alerta surgir, mais eficaz o gráfico será. Na verdade, a situação ideal seria a de que o gráfico nos alertasse assim que qualquer variação no processo ocorresse.

Seria interessante que, a princípio, em um processo produtivo composto por diversas etapas, a frequência de coleta das amostras de determinada etapa fosse menor do que o tempo em que o lote de peças processadas demorasse para chegar na etapa seguinte. Desta forma, a possibilidade de trabalharmos com peças que podem estar comprometidas seria minimizada.

No entanto, o tempo de detecção, que é conhecido como tempo esperado até o sinal (TES), depende, primeiramente, do próprio intervalo entre a coleta das amostras: se você coletou uma amostra e nenhum ponto fora dos limites foi encontrado, a produção continua e, caso alguma causa especial ocorra, ela só poderá ser detectada a partir da próxima amostra. Ou seja, não há como detectar variações no processo no tempo entre a coleta das amostras.

Além disso, lembre-se que estamos trabalhando com métodos estatísticos e não inspeção 100%. Desta forma, não há 100% de certeza de que consigamos identificar as variações no processo já na primeira amostra: existe uma probabilidade de que isso não ocorra. Nesse sentido, devemos levar em consideração o poder de detecção (Pd) dos gráficos, isto é a probabilidade de qualquer ponto ficar fora dos limites de controle (MONTGOMERY, 2001, MONTGOMERY; RUNGER, 2009), caracterizando, assim, sua capacidade de detectar os desvios no processo produtivo. Costa, Epprecht e Carpinetti (2016), por sua vez, alertam que tal aumento, pela mesma razão, faz com que haja um aumento

de alarmes falsos, isto é, pontos fora dos limites que não são, de fato, oriundos de causas especiais, mas tão somente variações naturais do processo (causas normais).

O Pd varia em função do tamanho das amostras (quanto maior a amostra, maior o poder de detecção do gráfico) e também do afastamento dos valores: intuitivamente sabemos que maiores afastamentos dos valores são mais fáceis e, em consequência, mais rapidamente detectados do que pequenos afastamentos. É como estar dentro de um veículo na estrada: pequenas mudanças de trajetória podem nem ser percebidas, ao passo que mudanças bruscas de direção chegam a nos assustar. Os afastamentos são medidos em desvios-padrões e são representados pela letra grega δ (delta). Os valores de Pd para os gráficos em função de δ e em função do tamanho das amostras são mostrados a seguir.

Tabela 7.12: Valores de Pd para os gráficos \bar{X} em função de δ e em função do tamanho das amostras

$\delta \backslash n$	2	3	4	5	6	7	8	9	10
0,25	0,004	0,005	0,006	0,007	0,009	0,010	0,011	0,012	0,014
0,50	0,011	0,016	0,023	0,030	0,038	0,047	0,056	0,067	0,078
0,75	0,026	0,044	0,067	0,093	0,122	0,155	0,190	0,227	0,265
1,00	0,056	0,102	0,159	0,222	0,291	0,362	0,432	0,500	0,564
1,25	0,109	0,202	0,309	0,419	0,525	0,621	0,704	0,773	0,830
1,50	0,190	0,344	0,500	0,638	0,750	0,834	0,893	0,933	0,959
2,00	0,432	0,679	0,841	0,930	0,971	0,989	0,996	0,999	1,000
3,00	0,893	0,986	0,999	1,000	1,000	1,000	1,000	1,000	1,000

Fonte: Adaptado de Costa, Epprecht e Carpinetti (2016, p. 71).



Para valores diferentes dos mostrados na **Tabela 7.12** (por exemplo, $n > 10$), veja em Costa, Epprecht e Carpinetti (2016, p. 69) como calcular os valores de Pd.

Uma forma fácil de compreender o significado e uso do Pd é a de que “o número médio de amostras até um alarme verdadeiro é igual a $1/Pd$ ” (COSTA; EPPRECHT; CARPINETTI, 2016, p. 69). Assim, quanto maior o Pd, menor a quantidade média de amostras esperada até que seja detectada uma variação no processo.

Por exemplo, um deslocamento de um desvio-padrão na média do processo (vide coluna δ da **Tabela 7.19**), para amostras com quatro medidas, apresenta um Pd de 0,159. Desta forma, é esperado que, em média, seja detectado com pouco mais de seis amostras ($1/0,159 \approx 6,3$), ao passo que um deslocamento de 1,5 desvios-padrões seja detectado em média com duas amostras ($1/0,500 = 2$).

Repare, também, que o mesmo deslocamento de um desvio-padrão, caso o tamanho da amostra fosse de $n = 9$, seria detectado, também, em média, em duas amostras ($1/0,500 = 2$). Observe, no entanto, que estamos considerando somente o deslocamento da média do processo, assumindo que não houvesse variação na dispersão: se ela acontecer, a tendência é de que a detecção ocorra mais rapidamente.



Para aprender mais sobre a análise conjunta dos gráficos \bar{X} -R, consulte Costa, Epprecht e Carpinetti (2016, p. 80).

Como estamos interessados em detectar as causas especiais o mais rapidamente possível, o TES torna-se, então, instrumento de análise para estabelecer o processo de coleta e análise das amostras para os gráficos de controle. O tempo esperado até o sinal (TES) é calculado pela seguinte equação:

$$TES = \frac{h}{Pd} - \frac{h}{2}$$

Sendo:

h = intervalo entre amostragens (em horas)

Antes de construirmos exemplos numéricos, vamos analisar os elementos da equação: se queremos o menor TES possível, é fácil perceber que isso aconteceria mediante a redução do h e o aumento do Pd . Ou seja, coletamos as medidas com maior frequência (reduzindo h) e utilizar grandes amostras (o que aumenta o Pd), mas isto seria algo lógico: mais amostras de maior tamanho tornariam o sistema de monitoramento por gráficos de controle mais robusto.

Isso implicaria maior tempo para coleta, medida e análise, bem como maiores custos de qualidade. Por outro lado, o relaxamento nos parâmetros para redução dos custos expõe a empresa a maiores riscos de custos de não qualidade, isto é, a produção de maiores volumes antes que os problemas fossem detectados. Trata-se de uma análise que precisa ser feita, com o objetivo de estabelecer um TES “ideal” para cada processo e produto a ser monitorado.

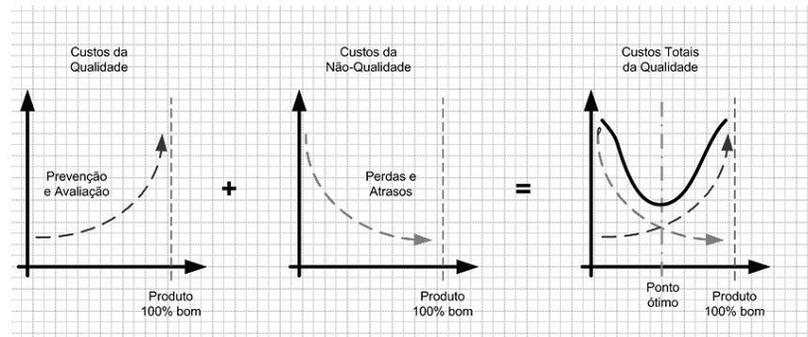


Figura 7.8: Custos da Qualidade e da Não Qualidade. O aumento da frequência e do tamanho das amostras faz com que haja um aumento nos custos. No entanto, tal ação reduz a possibilidade de falhas e defeitos (que representam custos), o que faz com que a decisão sobre a coleta das amostras varie de empresa para empresa e de processo para processo, não havendo uma regra geral.

Fonte: ACC PR (2016).

É importante destacar que podemos ter diferentes valores de TES para a mesma quantidade de medidas. Ou seja, devemos analisar se é melhor termos amostras maiores com intervalos maiores de coleta ou amostras menores coletadas mais frequentemente. Para compreender tal aspecto, vamos trabalhar com o seguinte exemplo comparativo: é preferível coletar amostras de $n = 2$ a cada meia hora ou amostras de $n = 4$ a cada hora? Repare que, em ambos os casos, estamos falando de um total de quatro medidas por hora. Será que há diferença entre os dois procedimentos?

Para responder a esta pergunta, basta utilizarmos o cálculo de TES. Vamos utilizar um $\delta = 1,5$. Temos, então, os seguintes valores:

Primeiro caso:

$$n = 2;$$

$$h = 0,5h.$$

Consultando a tabela de Pd, encontramos para $n = 2$ e $\delta = 1,5$, $P_d = 0,190$. Desta forma, o TES seria...

$$TES = 0,5/0,190 - 0,5/2 \approx 2,4 \text{ horas.}$$

Segundo caso:

$$n = 4$$

$$h = 1h.$$

Consultando novamente a tabela ($n = 4$ e $\delta = 1,5$), encontramos um $P_d = 0,500$. Assim...

$$TES = 1/0,500 - 1/2 = 1,5 \text{ hora.}$$

Observe, portanto, que a definição da frequência de coleta e do tamanho das amostras para o controle estatístico dos processos não é algo arbitrário, envolvendo análises de custo-benefício interessantes, com as quais o engenheiro deve lidar. A título ilustrativo, veja o gráfico a seguir, que apresenta o TES para diferentes valores de δ e o tamanho das amostras, considerando uma situação de 10 medidas coletadas por hora.

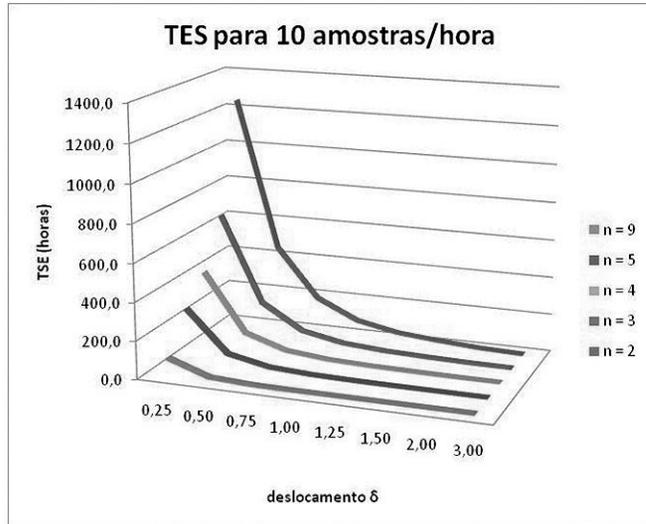


Figura 7.9: Tempo esperado até o sinal (TES), para diferentes deslocamentos (δ), em função do tamanho da amostra. Trata-se de um exemplo, considerando a coleta de 10 medidas por hora, mas é suficiente para evidenciar como a detecção é mais lenta para pequenos deslocamentos ($\delta \leq 1$), especialmente para amostras pequenas.

Testes de normalidade

Ainda que a regra principal de uso dos gráficos de controle seja a observação de existirem ou não pontos fora dos limites, é importante lembrar que se trabalha com a premissa de uma distribuição normal das medidas (COSTA; EPPRECHT; CARPINETTI, 2016), como mostrado na figura a seguir.

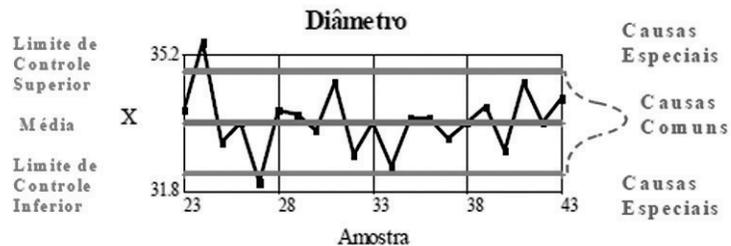


Figura 7.10: Exemplo de carta de controle. Repare a sobreposição de uma curva normal junto ao gráfico: os dados, aleatoriamente distribuídos, deveriam se aproximar de uma distribuição normal, com acúmulo de pontos mais próximos à região central e poucos pontos próximos dos limites de controle.

Fonte: Ribeiro e Caten (2012, p. 13).

A propósito, tal lógica explica a possibilidade de termos os chamados “falsos alarmes”, caracterizados por pontos fora dos limites que não estejam associados a causas especiais: é algo possível de acontecer, devido ao fato de trabalharmos com os limites calculados a partir de ± 3 desvios-padrões: existe uma probabilidade de 0,27% de termos pontos fora dos limites (vide figura a seguir).

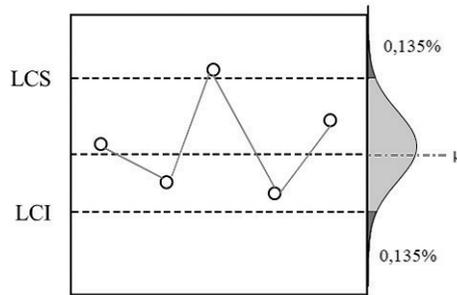


Figura 7.11: Nem todo ponto fora dos limites é, necessariamente, um indicativo de descontrole do processo. Existe uma pequena probabilidade de que não haja nenhuma causa especial e que o processo esteja submetido tão somente a causas comuns. É necessário proceder com uma investigação sobre o processo que está sendo monitorado, para compreender as causas.

Fonte: Ribeiro e Caten (2012, p. 43).

Para avaliar a normalidade da distribuição dos dados, podemos simplesmente construir histogramas com os valores coletados (vide Aula 5) (RIBEIRO; CATEN, 2012). Por ser um método simples, evitaríamos métodos estatísticos mais complexos, como os testes de valores críticos de assimetria e de curtose e os testes de Shapiro-Wilks e Kolmogorov-Smirnov (HAIR et al., 2014).

No entanto, uma pequena quantidade de amostras pode não ser suficiente para a construção de um histograma. Nesses casos, Ribeiro e Caten (2012) recomendam o uso do denominado “papel de probabilidade normal” (ou, folha de distribuição normal, simplesmente, papel normal), que permite testar graficamente o ajuste dos valores à uma distribuição normal.

Trata-se de um gráfico com uma escala vertical transformada, em que as medidas são sobrepostas a uma linha diagonal, que representa a distribuição perfeitamente normal, de forma que, se um conjunto de

dados segue a distribuição normal, suas frequências acumuladas aparecerão dispostas ao longo dessa linha reta, como mostrado na figura a seguir. Os afastamentos da linha representam resíduos: quanto mais próximos os pontos estiverem da reta, mais a distribuição se aproxima de uma normal.

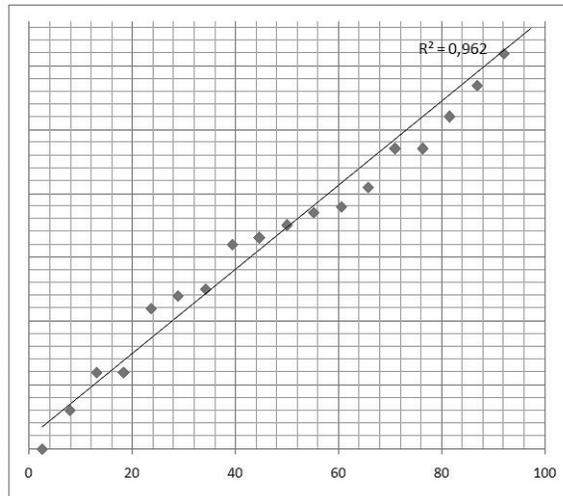


Figura 7.12: Exemplo de papel de probabilidade normal. A sobreposição ou notória proximidade dos pontos sobre a linha reta indicam que os valores estão distribuídos de forma aproximadamente normal.

Ou seja, “quando o modelo normal não se ajusta bem aos dados, suas frequências acumuladas irão apresentar curvatura quando plotadas no papel de probabilidade normal” (RIBEIRO; CATEN, 2012, p. 53). De acordo com os autores, caso não haja disponibilidade do gráfico papel de probabilidade normal, é possível, ainda, efetuar o teste gráfico de valores teóricos de Z, seguindo os seguintes passos (RIBEIRO; CATEN, 2012, p. 54):

- a) colocam-se os dados $X(i)$ em ordem crescente;
- b) calcula-se a probabilidade acumulada $F(X(i))$;
- c) obtém-se o valor teórico de Z a partir de $F(X(i))$, usando a tabela da distribuição normal acumulada;
- d) plota-se o Z teórico x $X(i)$;
- e) se o ajuste normal é adequado, os valores plotados devem aparecer seguindo, aproximadamente, uma linha reta.

A discussão sobre distribuição normal dos dados e padrões de distribuição dos mesmos nos gráficos de controle será retomada mais adiante, na Aula 9.

Atividade

Atende aos objetivos 1e 2

1. Retorne à questão do Enade apresentada nesta aula e responda-a, justificando a sua resposta.
2. A empresa Controle Total quer estabelecer os limites provisórios para seus gráficos de controle \bar{X} -s, referentes ao seu processo mais crítico. Para tanto, ela coletou 24 amostras de 10 medidas cada, com intervalo de uma hora entre as amostras, tendo obtido os seguintes resultados:

#	1	2	3	4	5	6	7	8	9	10	11	12
1	65	75	80	65	80	75	80	70	85	65	75	85
2	70	70	70	65	60	70	75	65	85	65	60	65
3	75	80	70	65	80	60	65	75	75	65	75	75
4	60	90	80	80	80	85	75	65	65	80	85	75
5	80	70	80	65	75	75	70	85	80	60	90	80
6	65	60	70	75	75	65	85	65	60	65	75	65
7	65	80	60	65	65	75	75	65	75	75	75	85
8	80	80	85	75	75	65	65	80	85	75	70	60
9	65	65	80	85	75	70	60	80	60	90	80	65
10	85	80	60	90	80	70	75	90	75	75	60	65

#	13	14	15	16	17	18	19	20	21	22	23	24
1	70	70	75	65	60	65	75	80	70	65	65	65
2	75	65	80	65	75	75	60	90	80	80	85	80
3	75	85	85	80	85	75	80	70	80	65	65	60
4	70	60	80	60	90	80	65	60	70	75	65	75
5	70	75	90	75	75	60	65	80	60	65	80	85
6	65	75	80	65	80	75	80	70	85	65	80	60
7	70	70	70	65	60	70	75	65	85	65	75	75
8	75	80	70	65	80	60	65	75	75	65	85	75
9	60	70	75	65	60	65	75	80	70	65	90	80
10	80	65	80	65	75	75	60	90	80	80	75	60

Podemos estabelecer limites provisórios para os gráficos de controle -s do citado processo?

3. A Controle Total está preocupada em garantir que deslocamentos da média de 1,5 desvios-padrões sejam detectados em menos de 2h. Isso é possível?

Resposta comentada

1. Considerando as alternativas:

a) Ampliar os limites das cartas de controle de ambas as máquinas para diminuir a variação da massa de enchimento das ampolas – *Os limites são estabelecidos para que possamos controlar os processos. Ao ampliar os limites, estaríamos comprometendo a capacidade dos gráficos de nos alertar sobre causas especiais.*

b) Adicionar uma operação posterior de inspeção 100%, após o processamento da máquina A, de forma a garantir a precisão dos princípios ativos – *Trata-se de um processo de alto volume e de difícil inspeção. Não faz sentido pensarmos em inspeção 100%, se já utilizamos o controle estatístico.*

c) Manter o processo produtivo de ambas as máquinas como está, uma vez que as cartas da média de valores apresentam variação insignificante – *Há pontos fora dos limites, o que nos indica que o processo está fora de controle.*

d) Atuar no processo da máquina A para se reduzir a variação da massa de enchimento e garantir a precisão dos princípios ativos – *Alternativa correta. Esta é a ação que deve ser tomada.*

e) Aumentar o tamanho das amostras do processo da máquina A, a fim de reduzir a amplitude da massa de enchimento das ampolas com valores superior a 100 – *Não faz sentido ficarmos alterando o tamanho de amostras, na expectativa de obter gráficos com “bons resultados”. Os gráficos nos auxiliam a identificar problemas nos processos e, assim, se há problemas, devemos atuar nos processos, e não nos gráficos.*

2. Calculamos os valores médios e os limites para o gráfico de controle \bar{X} , considerando o fator A3 ($n = 10$) = 0,975, temos:

$$LCS = 80,7$$

$$LC = 72,7$$

$$LCI = 64,7$$

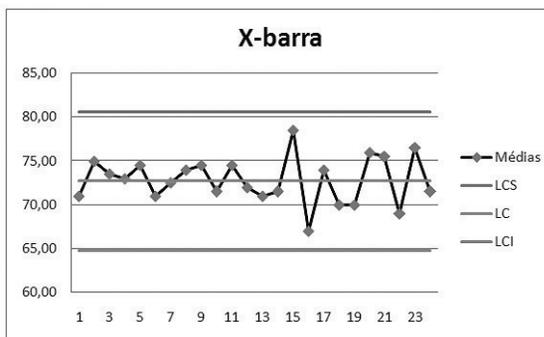
Fazendo o mesmo para o gráfico de controle s, considerando B3 = 0,284 e B4 = 1,716 ($n = 10$), temos:

$$LCS = 14,0$$

$$LC = 8,2$$

$$LCI = 2,3$$

Construímos, então, os gráficos de controle -s do citado processo:



Constatamos, então, que não há pontos fora dos limites e, conseqüentemente, não foram detectadas causas especiais. Desta forma, os limites podem ser utilizados como limites provisórios para o monitoramento do processo.

3. Para $\delta = 1,5$ e $n = 10$, o $P_d = 0,959$. Assim, podemos calcular o TES:

$$\text{TES} = 1/0,959 - 1/2 \approx 0,54 \text{ horas.}$$

É esperado que haja sinais se o $\delta = 1,5$ em menos de 2h: em média, em aproximadamente 32 minutos.

Conclusão

A mais sofisticada das ferramentas da qualidade, o gráfico de controle, desenvolvida por Shewhart há quase 100 anos, tornou-se um pilar para o desenvolvimento do controle da qualidade, trazendo a ciência (em especial, a estatística) para o chão de fábrica e, posteriormente, para todas as áreas das empresas. A noção de estabilidade do processo, isto é, de podermos ter avisos de variações inesperadas nos processos produtivos de qualquer ramo de atividade, que podem servir de alertas sobre qualquer descontrole ou problema, trouxe a possibilidade de nos anteciparmos aos problemas, ao invés de agirmos reativamente aos resultados negativos de inspeções.

E o conceito do controle estatístico de processos (ou controle estatístico da qualidade) continua evoluindo, junto ao desenvolvimento de modelos matemáticos, ferramentas computacionais, pacotes estatísticos e de simulação, sistemas de sensoriamento remoto, bem como controles lógicos e automação, fazendo com que possamos ter cada vez mais processos produtivos com maior capacidade, mas, também, mais robustos, mediante a autorregulação, quando ocorrem desvios.

Assim, o conhecimento das bases dos gráficos de controle é uma exigência para a atuação profissional dos engenheiros de produção, que os utilizam nas mais diversas atividades, não somente na área de produção, mas, também logística, engenharia de confiabilidade, assistência técnica e serviços, comunicações, etc.

Resumo

Para o controle e melhoria da qualidade, é comum a utilização de ferramentas, quais sejam:

- estratificação;
- folha de verificação;
- diagrama de dispersão;
- gráfico de pareto;
- diagrama de causa e efeito;
- histograma;
- gráficos de controle.

Os gráficos de controle – que, originalmente, se limitavam a analisar os valores médios e a dispersão por meio da amplitude das amostras – puderam ser expandidos para cálculos mais precisos que analisam a dispersão por meio dos desvios-padrões das amostras, isto é a utilização de gráficos \bar{X} -s, em substituição aos gráficos \bar{X} -R: o que inicialmente tinha limitações para uso no chão de fábrica, devido à complexidade dos cálculos envolvendo tal medida, tornou-se mais fácil mediante a disseminação no uso de computadores e até mesmo softwares estatísticos.

Ainda que a determinação dos limites de controle dos gráficos de controle se baseiem em valores históricos, podemos estabelecer valores provisórios quando iniciamos ou remodelamos um processo. Nessas situações, a indicação de valores fora dos limites deve ser analisada e, eventualmente, algumas amostras devem descartadas, visto que nosso interesse naquele momento não é avaliar a estabilidade de um processo, mas sim estabelecer limites de controle que caracterizem somente a influência de causas comuns (por isso, descartamos o que for indício de causa especial).

Também é importante definir-se o processo de coleta de amostras, isto é, a frequência de coleta e o tamanho das amostras, o que leva em consideração a quantidade média de amostras esperada até que haja um sinal, isto é, até que seja detectada uma variação no processo, bem como o TES (tempo médio esperado até o sinal). Entretanto, ter pontos somente dentro dos limites de controle não é a única exigência para caracterizarmos que um processo esteja sob controle: as causas especiais

geram variações randômicas e, conseqüentemente, os valores coletados devem estar normalmente distribuídos, o que pode ser testado mediante a construção de histogramas, pelo uso do papel normal, ou testes estatísticos.

Leituras recomendadas

DAMINELLI, Laís Marques. *Análise do peso do biscoito laminado: aplicação do controle estatístico do processo*, 2013. 55 f. Trabalho de conclusão de curso (Bacharelado em Engenharia de Produção) – Universidade Tecnológica Federal do Paraná, Medianeira, 2013. Disponível em: http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/1734/1/MD_COENP_%202013_1_13.pdf. Acesso em: 17 jan. 2019.

Informação sobre a próxima aula

Na próxima aula, continuaremos os estudos dos gráficos de controle, com foco nos gráficos por atributos.

Referências

ACC PR. Entendendo os custos da qualidade e seus impactos econômicos. *ACC PR Engenharia de Medição*. 05 fev. 2016. Disponível: <http://www.accpr.com.br/entendendo-os-custos-da-qualidade-e-seus-impactos-economicos/>. Acesso em: 23 jan. 2019.

AFFONSO, Ligia Maria Fonseca. A evolução histórica da qualidade. In: PEZZATTO, A. T. *Sistemas de controle da qualidade*. Porto Alegre: Sagah, 2018, p. 35-56.

CHRISTO, E. S. *Aula 7 – Ferramentas para o controle da qualidade*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 6), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=9>. Acesso em: 25 fev. 2019.

COSTA, Antônio Fernando Branco; EPPRECHT, Eugenio Kahn; CARPINETTI, Luiz César Ribeiro. *Controle estatístico de qualidade*. 2. ed. São Paulo: Atlas, 2016.

HAIR Jr., Joseph F.; BLACK, William C.; BABIN, Barry J.; ANDERSON, Rolph E. *Multivariate Data Analysis*. 17th ed. Essex: Pearson Education, 2014.

INEP. *Enade 2017*. Engenharia de Produção: Bacharelado. Disponível em: http://download.inep.gov.br/educacao_superior/enade/provas/2017/15_ENG_PRO_BACHAREL_BAIXA.pdf. Acesso em: 21 jan. 2019.

MICROSOFT. *Funções estatísticas* (referência). Disponível em: <https://support.office.com/pt-br/article/fun%C3%A7%C3%B5es-estat%C3%ADsticas-refer%C3%A2ncia-624dac86-a375-4435-bc25-76d659719ffd>. Acesso em: 20 jan. 2019.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. 4th ed. New York: John Wiley & Sons, 2001.

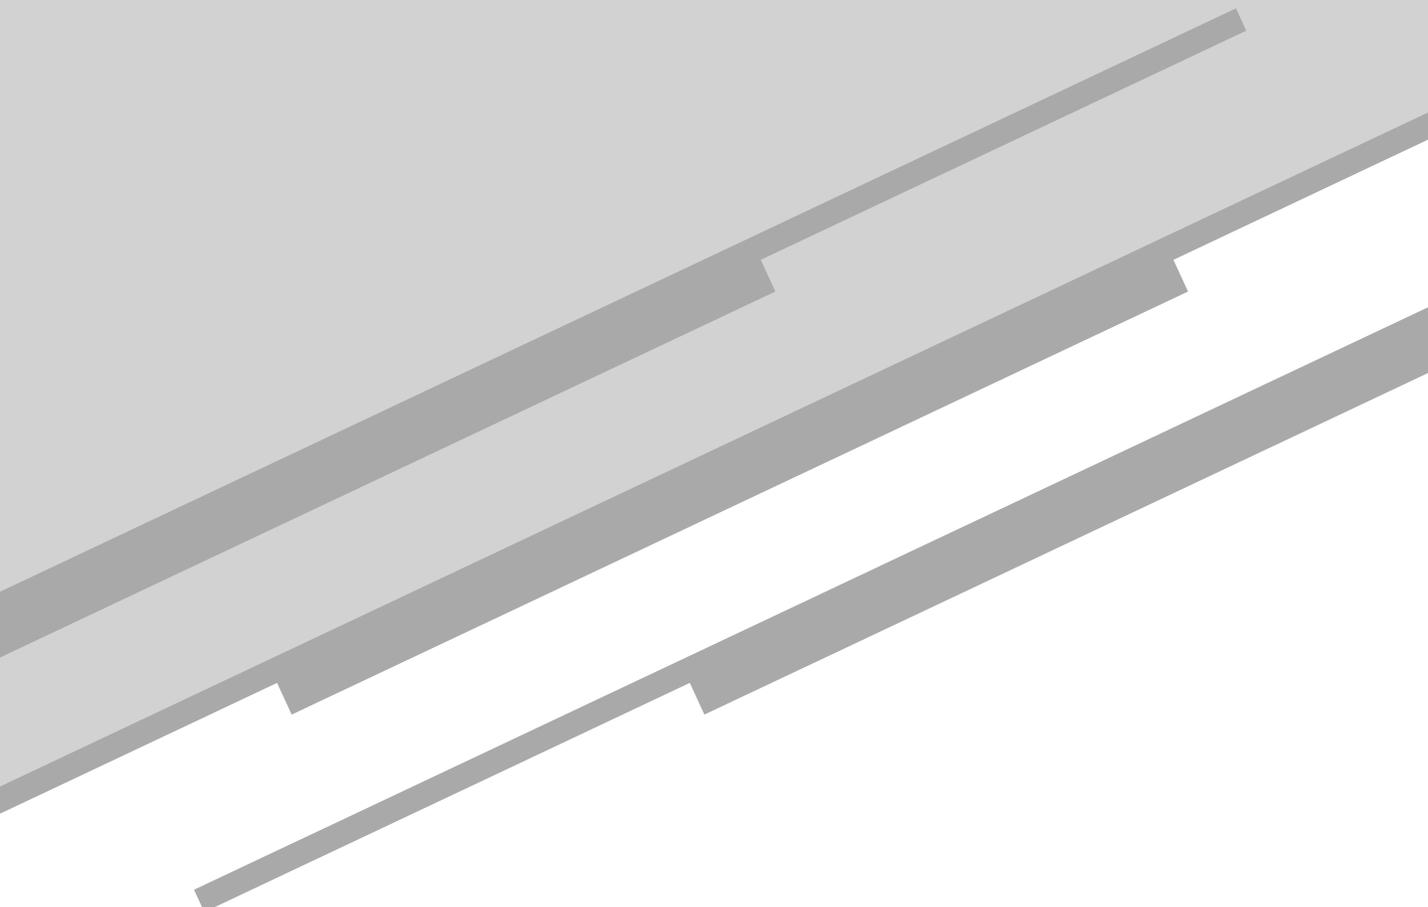
MONTGOMERY, D. C.; RUNGER, G. C. *Estatística aplicada e probabilidade para engenheiros*. 4. ed. Rio de Janeiro: LTC, 2009.

RIBEIRO, José Luis Duarte; CATEN, Carla Schwengber ten. *Controle estatístico do processo: cartas de controle para variáveis, cartas de controle para atributos, função de perda quadrática, análise de sistemas de medição*. Série monográfica Qualidade. Porto Alegre: FEENG/UFRGS – Fundação Empresa Escola de Engenharia da UFRGS – Universidade Federal do Rio Grande do Sul, 2012.

SAMOHYL, R. W. *Controle estatístico de qualidade*. Rio de Janeiro: Campus, 2009.

Aula 8

Ferramentas para o controle da qualidade:
gráfico de controle (continuação)



Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. saber como utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. conhecer o gráfico de controle ou cartas de controle para variáveis e para atributos, que representa uma das ferramentas mais utilizadas no controle da qualidade.

Pré-requisitos

Funções estatísticas e distribuição normal, distribuição binomial, distribuição de bernoulli, ciclo PDCA, estratificação, folha de verificação, causas comuns e causas especiais, gráficos \bar{X} -R e \bar{X} -s, conteúdos abordados nas aulas anteriores.

Introdução

A complexidade de produtos e processos nos dias atuais faz com que as exigências de controle dos processos por meio de gráficos específicos se tornem uma necessidade. Mas, em termos práticos, é impossível controlar estatisticamente todas as medidas de todos os componentes de um produto.

Como solução, surge o conceito dos gráficos de controle por atributos, que avaliam um processo produtivo como um todo, ao monitorar defeitos e unidades defeituosas nele geradas. Tal abordagem permite detectar problemas, direcionando os esforços seguintes para identificação de suas causas, usualmente alocadas em componentes e peças específicas.

É isso que você estudará aqui: você continuará estudando o gráfico de controle, mas, agora, aprendendo sobre outra família de gráficos, que são os gráficos de controle por atributos. Bons estudos!

A qualidade tem diversas dimensões, como você aprendeu na Aula 1, em especial a conformidade (grau em que as peças executadas correspondem ao projeto) e desempenho (características primárias de um produto) (GARVIN, 1984; 2002).

Poderíamos fazer uma associação de tais dimensões com os/as tipos/famílias de gráficos de controle (vide Aula 6): a ideia de conformidade tem clara vinculação com os gráficos ou cartas de controle por variáveis que você estudou nas Aulas 6 e 7, isto é, o de peças e componentes estarem “dentro das medidas (ou das especificações)”, o que tem no acompanhamento dos processos por meio de gráficos de controle \bar{X} -R e \bar{X} -s um forte aliado. O acompanhamento das variações de dimensões críticas por meio de tais gráficos e os alertas oriundos de variações excessivas (fora dos limites de controle), normalmente decorrentes de causas especiais agindo sobre os processos, nos permitem monitorar os processos produtivos e nos anteciparmos a eventuais falhas decorrentes de processos fora de controle.

Já a dimensão desempenho parece estar relacionada a algo como “funcionar bem” ou não, ou ainda “ter defeitos” ou não. Ou seja, tem clara associação com os gráficos de controle por atributos, isto é, que lidam com variáveis discretas: “o que contamos”, ao invés de “o que medimos”. Nessa categoria, podemos englobar defeitos e falhas diversas.



Figura 8.1: Quebra em um automóvel. As falhas e defeitos são os aspectos mais perceptíveis e de impacto direto sobre os clientes e usuários de produtos. As causas-raiz destes podem estar relacionadas a falhas dimensionais ou construtivas de peças e componentes.

Fonte: <https://pixabay.com/pt/automotivo-defeito-quebrado-62827/>

De acordo com Christo (2017, p. 3),

Existem situações em que as características da qualidade não podem ser medidas numericamente. Por exemplo, uma lâmpada é classificada como “funciona” ou “não funciona”. Ou seja, existem casos em que as características da qualidade são mais bem representadas pela presença ou ausência de um atributo, e não por alguma medição.

Desta forma, os gráficos de controle por atributos, ainda que sigam a mesma lógica dos gráficos de controle por variáveis, com limites de controle estabelecidos a partir de dados históricos e análises estatísticas dos valores e da dispersão, são utilizados com um foco diferente, ignorando dimensões para se preocupar com defeitos e unidades defeituosas.

A dúvida que pode surgir é a seguinte: se falhas e defeitos são aspectos indesejados, usualmente interpretados como problemas de qualidade, qual a lógica de termos limites em gráficos de controle, em especial, limites inferiores? Isso não seria “achar normal” a existência de defeitos e, conseqüentemente, tratar como algo anormal ter “poucos” defeitos (ou seja, abaixo do limite inferior de controle)? Reflita um pouco sobre isso...

Imagine a seguinte situação: um grande fabricante de automóveis, que produz centenas de unidades a cada dia, vem registrando em torno de 10 a 15 defeitos por dia na área de inspeção final, a qual analisa aspectos estéticos como pintura, folgas, ruídos, etc., bem como aspectos funcionais. Ações diversas são adotadas pela empresa todos os dias, com base nos relatos de tais defeitos, o que inclui alterações na forma de armazenagem ou embalagem dos componentes, retreinamento de operadores, mudanças nos processos de montagem, etc.

Raramente os problemas se repetem, por conta de tais ações. No entanto, devido à complexidade do processo e da diversidade de peças (um automóvel é composto por milhares de componentes) e operações, acabam ocorrendo novos problemas, razão pela qual não é observada uma redução significativa na quantidade média de defeitos por dia. Até que, determinado dia, nenhum defeito é registrado! Como você se sentiria? Feliz pelo bom resultado? Surpreso por ser algo inesperado? Desconfiado?



Figura 8.2: Reação a uma boa notícia sobre a qualidade. Se os defeitos têm ocorrido regularmente, seria motivo de satisfação o fato de eles cessarem, de uma hora para outra, sem qualquer explicação? Ou soaria como uma notícia “boa demais” para ser verdade, o que nos levaria a desconfiar desta? Os bons resultados em qualidade não ocorrem ao acaso: são fruto de um esforço estruturado e da busca constante pela melhoria em termos de processos de trabalho.

Fonte: https://www.freepik.com/free-vector/office-emotions-poses_1528635.htm

Após um possível momento de euforia, você começaria a se questionar se aquilo era, de fato, um bom sinal, isto é, um bom resultado. Se nada de diferente fora feito, além das ações usuais com base nos problemas encontrados, o que explicaria a total ausência de defeitos? Ciente da complexidade dos produtos e processos, bem como da diversidade de problemas ocorridos, não faria sentido supor que os problemas haviam simplesmente “terminado”, não é mesmo?

Na verdade, é bem provável que você começasse a pensar em outras possibilidades: erro nos registros, falhas na inspeção, etc., o que não seria nem um pouco interessante para a empresa, por mascarar os problemas e, conseqüentemente, podendo levar a uma situação de agravamento dos problemas em breve. Se a quantidade de defeitos tivesse reduzido “um pouco”, você não teria tal tipo de preocupação, porém, essa mudança súbita, extrema, parece indicar algum tipo de problema nos processos.

Você consegue associar tal análise aos conceitos de causas comuns e causas especiais, que você estudou na Aula 6?

Veja que, ainda que haja esforços para a melhora da qualidade e redução da quantidade de defeitos, uma melhoria brusca e sem explicação não é um bom sinal: ao contrário, costuma ser motivo de maiores preocupações e deve haver uma investigação para se compreender o que houve, ou seja, qual causa especial originou tal situação. Trata-se, exatamente, da mesma lógica adotada quando analisamos os gráficos de controle por variáveis: valores dentro dos limites de controle indicam que o processo está sob controle (ou, em estado de controle estatístico), sujeito tão-somente a causas comuns, ao passo que pontos fora dos limites, sejam “para cima” ou “para baixo” (acima do limite superior ou abaixo do limite inferior), seriam sinais de um processo provavelmente fora de controle. Vamos, agora, compreender como são definidos tais limites, isto é, a lógica construtiva e de que forma se dá a análise dos gráficos de controle por atributos.

Gráficos de controle por atributos

Ribeiro e Caten (2012) destacam que o controle por atributos seria um sumário do que acontece no processo produtivo. Ou seja, eventuais não conformidades dimensionais ou de características de componentes diversos (monitorados pelos gráficos de controle por variáveis) seriam causas de defeitos nos produtos e, desta forma, ao monitorarmos o processo produtivo por gráficos de controle por atributos, estaríamos monitorando “em conjunto” todos os componentes envolvidos, de uma forma global. Desta forma, de acordo com os autores, problemas identificados nos gráficos por atributos poderiam ser alertas para disparar investigações envolvendo a análise (e mesmo monitoramento) das variáveis.

“Cartas de atributo exigem subgrupos de tamanho considerável (em geral, 50 a 200 unidades ou mais) para serem eficientes na detecção de alterações no processo” (RIBEIRO; CATEN, 2012, p. 86). Os gráficos por atributo são utilizados geralmente nas seguintes situações (CHRISTO, 2017, p.3):

1. quando o número de características a controlar em cada produto é muito grande;

2. em lugar de mensurações, convém empregar calibradores do tipo passa-não passa;
3. o custo de mensuração é elevado em relação ao custo da peça;
4. a verificação da qualidade pode ser feita por simples inspeção visual.

Ramos, Almeida e Araújo (2013, p.75) definem atributo como “uma característica da qualidade representada pela ausência ou presença de não conformidade em um processo ou serviço, onde não conformidade significa falha no atendimento das necessidades e/ou expectativas do cliente”. Desta forma, as não conformidades (ou defeitos) e os produtos não conformes (ou defeituosos) são o foco de atenção dos gráficos de controle por atributos.

Os conceitos de não conformidades e não conformes ou defeitos e defeituosos podem parecer um mero jogo de palavras, tratando da mesma coisa. Mas, isso não é verdade: trata-se de conceitos distintos. Assim, antes de estudarmos os gráficos de controle por atributos, precisamos compreender e diferenciar os conceito de defeito e o conceito de unidade defeituosa, visto que tais conceitos são utilizados para diferentes tipos de gráficos.



É comum encontrarmos a forma abreviada NC significando tanto não conformidades como não conformes. A diferenciação ocorre por meio da interpretação do contexto: por exemplo, se falamos de defeitos, 10 NC serão 10 não conformidades, ao passo que, se fizermos referência a 10 unidades de produto com defeito, 10 NC significarão 10 produtos não conformes.

Para isso, vamos tomar como exemplo um lote de bolas de natal: o descascamento da pintura é um dos tipos de problemas em enfeites de natal e, assim, vamos observar o lote de cinco bolas mostrado a seguir, no qual algumas bolas apresentam descascamento na sua pintura.

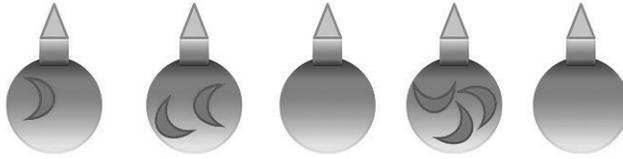


Figura 8.3: Lote de bolas de natal. Como você pode observar, algumas delas apresentam defeitos (descascamentos), na forma de “luas”. Por se tratar de um objeto que tem como função enfeitar as árvores, o aspecto estético é muito importante e defeitos como este afastam os compradores, sendo um problema para o fabricante.

Quanto defeitos (não conformidades) e quantos enfeites defeituosos (não conformes) temos no lote? Bem, você pode identificar que, das cinco bolas que compõem o lote, três delas apresentam algum descascamento. Ou seja, há três bolas defeituosas (ou não conformes), o que representa 60% do lote. Mas, também, um olhar mais atento mostra que há bolas com mais de um defeito, isto é, mais de um descascamento.

A contagem dos defeitos (ou das não conformidades) apresenta um total de seis defeitos (não conformidades, na forma de descascamentos), o que representa, assim, 1,2 defeitos por bola ($6 \text{ não conformidades} \div 5 \text{ unidades} = 1,2$). São essas formas de medir defeitos ou unidades defeituosas que estabelecem os diferentes tipos de gráficos por atributo, como resumido no quadro a seguir (que você já viu na Aula 6), que apresenta os quatro tipos de gráfico por atributo, bem como o que eles contabilizam/monitoram e as características das amostras.

Tabela 8.1: O que é contado em cada tipo de gráfico

Tipo de gráfico	O que é “contado”	
	Defeitos (não conformidades)	Defeituosos (não conformes)
Tamanho das amostras		
=	c – quantidade de defeitos	np – quantidade de unidades defeituosas
= ou ≠	u – defeitos/unidade	p – proporção defeituosa

Assim, retornando ao exemplo das bolas de natal, teríamos:

- as três bolas defeituosas (ou não conformes) seriam a forma de monitoramento característica dos gráficos *np*;

- a proporção de 60% (0,6) bolas defeituosas seria o tipo de análise feita com os gráficos p ;
- os seis defeitos (não conformidades) seriam vistos pelos gráficos c ; e
- a média de 1,2 defeitos por bola é o que vemos ao utilizar os gráficos u .



Observação: ao contrário dos gráficos de controle por variáveis, os gráficos por atributos não são utilizados em pares, isto é, não há o gráfico de dispersão, somente o de valores.

Vamos estudar as características e aplicações de cada um desses quatro gráficos de controle.

Gráfico p (proporção defeituosa, proporção não conforme, ou fração defeituosa)

O gráfico utilizado para controlar a proporção defeituosa de peças, isto é, de peças não conformes no total de peças produzidas é o gráfico p (PEINADO; GRAEML, 2007). O mesmo trabalha, assim, com a fração defeituosa, ou seja, a razão entre a quantidade de peças defeituosas em uma amostra e o tamanho desta mesma amostra (CHRISTO, 2017), “mesmo na ausência de causas especiais” (COSTA; EPPRECHT; CARPINETTI, 2016, p. 199), como indicado na equação a seguir:

$$p = d / n$$

Sendo:

p = proporção (ou fração) defeituosa;

d = quantidade de itens defeituosos (não conformes) e

n = quantidade de itens inspecionados (tamanho da amostra).

A construção dos gráficos p só é possível se as seguintes condições forem satisfeitas (GRÁFICO P, [201-]):

$$n * \bar{p} \geq 5$$

$$n * (1 - \bar{p}) \geq 5$$

Sendo:

n = tamanho da amostra e

\bar{p} = proporção média de unidades defeituosas.

Tais limites se justificam pelo fato de que, como defendido por Montgomery (2001) e Walpole et al. (2009), proporções muito pequenas de unidades defeituosas exigiriam tamanhos de amostras muito grandes para que o gráfico p tivesse poder suficiente de detecção. Por exemplo, uma proporção de 0,001 unidades defeituosas (0,1%) em amostras com tamanho $n = 1.000$ faria com que a quantidade média de não conformes por amostra fosse 1 ($0,001 \times 1.000 = 1$). Isto faria com que houvesse uma grande quantidade de valores zero no gráfico, ao passo que na proporção de 0,15 defeituosas (15%) com amostras de $n = 50$, o valor médio de unidades defeituosas seria de 7,5 por amostra.

E a frequência de coleta da amostra “deve fazer sentido em termos de períodos de produção” (RIBEIRO; CATEN, 2012, p. 86), ou seja, horária, por período, por troca de turno, diária, por lote, etc. sendo que Ribeiro e Caten (2012) e Lozada (2017) recomendam um mínimo de 25 amostras.



Os planos de amostragem, isto é, as decisões quanto a frequência de coleta e tamanho das amostras, bem como os critérios de aceitação e rejeição de lotes, serão discutidos mais adiante, nas aulas 11 e 12.

Para calcularmos os limites do gráfico p , utilizamos as seguintes equações:

$$LC = \bar{p} = \frac{d1 + d2 + \dots + dk}{n1 + n2 + \dots + nk}$$

Sendo:

$d_1, d_2, \text{ etc.}$ = quantidade de unidades não conformes na amostra 1, 2, etc.;

$n_1, n_2, \text{ etc.}$ = tamanho da amostra 1, 2, etc.



Ainda que a utilização de amostras com tamanhos distintos possa parecer um fato complicador, Costa, Epprecht e Carpinetti (2016, p. 215) apontam que situações ocasionais em que a quantidade de unidades produzidas desde a retirada da amostra anterior é inferior ao estabelecido podem fazer com que o tamanho das amostras varie. Nesse sentido, o uso do gráfico p torna-se um aliado, pois a flexibilidade de poder trabalhar dessa forma evita que a coleta de dados para o gráfico de controle seja comprometida.

$$LCS = \bar{p} + 3\sigma_p$$

$$LCI = \bar{p} - 3\sigma_p$$

Sendo:

σ_p = desvio-padrão da amostra.

Costa, Epprecht e Carpinetti (2016, p. 215) destacam que “uma das vantagens de trabalhar com o gráfico p é que sua linha central, que corresponde à proporção média de não conformes do processo, informa diretamente o nível de qualidade do processo (quanto menor o valor da linha central, melhor o nível de qualidade)”. Os princípios estatísticos que servem de base ao gráfico p (e, também, ao gráfico np) são os da distribuição binomial, em conformidade com o pressuposto da variável aleatória de Bernoulli (KAZMIER, 2007; COSTA; EPPRECHT; CARPINETTI, 2016; LOZADA, 2017), ou seja, uma distribuição discreta

de espaço amostral (0 e 1), com eventos independentes em que o valor 1 tem probabilidade de ocorrência p e o valor 0 tem probabilidade $q = 1 - p$. Assim, o valor 1 seria a ocorrência de uma unidade defeituosa, enquanto o valor zero seria a não detecção de unidades não conformes.



Distribuição binomial, de acordo com Zibetti (s.d.), “é aplicada em casos de experimentos repetidos, onde existem dois possíveis resultados: cara ou coroa, sucesso ou fracasso, item defeituoso ou item não defeituoso, entre muitos outros possíveis pares”. De acordo com o autor, uma variável aleatória poderá ter sua distribuição de probabilidade modelada de forma binomial caso atenda aos seguintes pressupostos:

- o resultado é completamente determinado por chance (aleatório);
- existem somente dois possíveis resultados (experimento Bernoulli);
- todas as tentativas possuem a mesma probabilidade para um resultado em particular. Ou seja, as tentativas ou realizações do experimento são independentes;
- isso implica que, existe uma probabilidade p de sucesso constante em cada tentativa;
- o número de tentativas, n , é um valor fixo, um número inteiro e positivo;

As variáveis de Bernoulli podem assumir dois valores numéricos: 0 ou 1, em que 1 corresponde a um evento e 0 corresponde a um não evento. Uma variável aleatória X segue uma distribuição de Bernoulli se, $P(X = 1) = p$ e $P(X = 0) = 1 - p$, em que p é a probabilidade de ocorrência de um evento (MINITAB, 2017a).

Se a variável aleatória X tem distribuição de Bernoulli, com parâmetro p , temos como esperança estatística e variância, respectivamente, $E(X)=p$ e $\text{Var}(X)=p(1-p)$.

Desta forma, o desvio-padrão para tal distribuição é dado pela seguinte equação:

$$\sigma_p = \sqrt{\frac{\bar{p}(1-\bar{p})}{n}}$$

Desta forma, temos os seguintes limites pra o gráfico p :

$$LCS = \bar{p} + 3\sqrt{\frac{\bar{p}(1-\bar{p})}{n}}$$

$$LCI = \bar{p} - 3\sqrt{\frac{\bar{p}(1-\bar{p})}{n}}$$



Observação: caso o cálculo do limite inferior resulte em um valor negativo, utilizamos para limite inferior de controle o valor zero, visto que não faria sentido uma proporção negativa de unidades defeituosas.

Mas, vamos a uma peculiaridade do gráfico p : como ele trabalha com proporções, ele aceita bem trabalhar com tamanhos de amostras diferentes. Por exemplo, uma amostra de tamanho 100 que apresente cinco unidades não conformes apresenta um $p = 0,05$, ao passo que uma amostra de tamanho 120 com seis unidades defeituosas apresentaria o mesmo valor de p ($6 \div 120 = 0,05$). Assim, podemos lidar com a identificação do valor médio das proporções p , mesmo que as amostras tenham tamanho diferente.

No entanto, o mesmo não acontece com o desvio-padrão: repare que o valor de n aparece no denominador da raiz e, conseqüentemente, mesmo para o mesmo valor de p , valores distintos de n resultarão em diferentes valores do desvio-padrão e isso afetará diretamente o valor dos limites de controle. Ou seja, teremos, no caso de tamanhos diferentes das amostras, a situação de ter valores distintos para os limites de controle para amostras de tamanho diferente, como mostrado no exemplo a seguir.

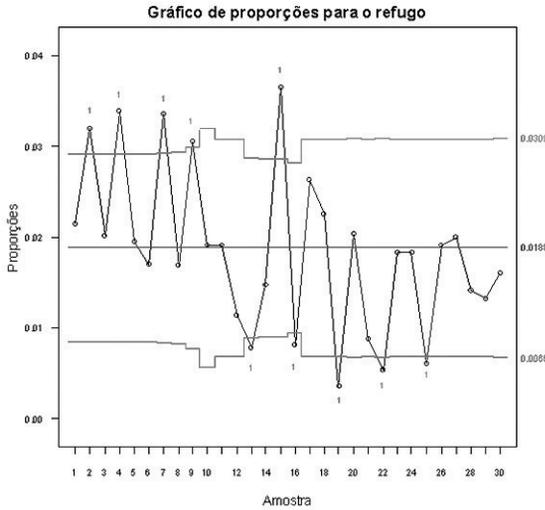


Figura 8.4: Gráfico de controle p, referente a amostras de tamanhos diferentes. Como você pode observar, os limites de controle não são constantes: eles variam em função do tamanho das amostras. A análise visual, no entanto, permanece como vimos até o momento: valores acima do limite superior ou abaixo do limite inferior são indicativos de potenciais problemas.

Fonte: Gráfico p, [201-].

Nesse sentido, há uma possibilidade interessante para simplificar os gráficos: apesar de Ribeiro e Caten (2012, p. 86-87) estabelecerem que, “se a diferença nos tamanhos de amostras for pequena (< 25%), pode-se usar a média dos tamanhos de amostras”, Costa, Epprecht e Carpinetti (2016) adotam uma posição mais conservadora. De acordo com os autores, podemos construir o gráfico de controle p , adotando para cálculo dos limites o n referente à maior amostra.

A lógica é a de que um n maior fará com que o valor do desvio-padrão seja menor (repare na fórmula que o n entra no denominador) e, conseqüentemente, os limites serão mais “apertados”. Tal abordagem evitará que aprovemos pontos que estariam fora dos limites, caso utilizássemos a média, como proposto por Ribeiro e Caten (2012). Mas, por outro lado, poderíamos identificar alarmes (pontos fora dos limites) que são falsos, pois, ao adotarmos limites mais estreitos, poderíamos interpretar como fora de controle um processo que, de fato, não estivesse: tal erro seria causado por limites demasiadamente estreitos.

Para solucionar tal situação, os autores sugerem que pontos que se posicionem fora dos limites de controle sejam verificados separadamente, para que nos certifiquemos se são indicativos reais de problemas, ou

somente uma questão de limites muito “apertados”. Vamos ver como isso funciona, em um exemplo adaptado de Costa, Epprecht e Carpinetti (2016), em que cinco amostras, cujo tamanho variava entre 200 e 240 unidades, apresentavam os seguintes valores:

Tabela 8.2: Valores de cinco amostras que variam entre 200 e 240 unidades

Amostra	n	NC	p	LCS	LCI
1	200	8	0,0400	0,0962	0,0038
2	240	13	0,0542	0,0922	0,0078
3	220	3	0,0136	0,0941	0,0059
4	240	12	0,0500	0,0922	0,0078
5	200	19	0,0950	0,0962	0,0038

Construindo o gráfico de controle p , tomando por base os limites de controle referentes às maiores amostras ($n = 240$), quais sejam, $LCS = 0,0922$ e $LCI = 0,0078$, temos:

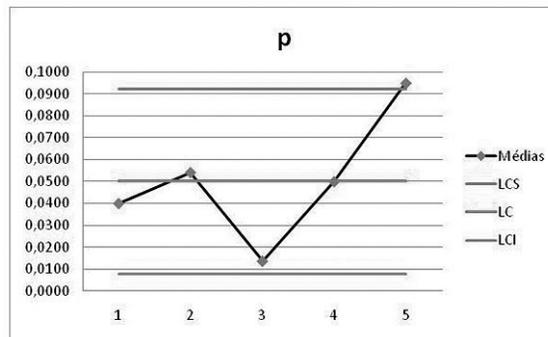


Figura 8.5: Gráfico de controle p , tomando por base os limites de controle referentes às maiores amostras ($n = 240$), quais sejam, $LCS = 0,0922$ e $LCI = 0,0078$.

Como você pode perceber, o último ponto, referente à amostra #5, apresenta um ponto acima do limite superior, o que seria indício de um problema no processo. No entanto, é necessário verificarmos se isso é um fato real, ou se estamos “condenando” o ponto devido a utilizarmos um limite muito severo.

Repare que o p da amostra #5 é 0,0950, valor superior ao LCS adotado (0,0922). No entanto, o sinal de alarme só deveria ser confirmado caso tal ponte estivesse acima do valor do limite calculado, ou seja, acima de 0,0962. No entanto, como $0,0950 < 0,0962$, tal ponto não será caracterizado como um ponto fora dos limites e, conseqüentemente, iríamos inferir que tal processo está sob controle.

Vamos, agora, resolver um exercício completo, tomando por base o exemplo apresentado por Ribeiro e Caten (2012, p. 88), em que os dados mostrados representam a quantidade de eixos defeituosos (d) de um modelo de motor. Para efeito de simplificação, vamos assumir que todas as 30 amostras são do mesmo tamanho ($n = 80$) (lembre-se que o gráfico p pode ser utilizado tanto para amostras do mesmo tamanho, como de tamanhos diferentes).

Tabela 8.3: Valores de 30 amostras

Amostra	d	Amostra	d	Amostra	d
1	9	11	18	21	25
2	11	12	13	22	16
3	5	13	23	23	10
4	8	14	9	24	13
5	17	15	11	25	8
6	10	16	6	26	14
7	15	17	14	27	10
8	11	18	12	28	7
9	6	19	21	29	13
10	7	20	19	30	16

Iniciamos com o cálculo do valor de p para cada amostra (dividindo d por $n = 80$), como mostrado a seguir:

Tabela 8.4: Cálculo do valor de p

Lote	d	p	Lote	d	p	Lote	d	p
1	9	0,113	11	18	0,225	21	25	0,313
2	11	0,138	12	13	0,163	22	16	0,200
3	5	0,063	13	23	0,288	23	10	0,125
4	8	0,100	14	9	0,113	24	13	0,163
5	17	0,213	15	11	0,138	25	8	0,100
6	10	0,125	16	6	0,075	26	14	0,175
7	15	0,188	17	14	0,175	27	10	0,125
8	11	0,138	18	12	0,150	28	7	0,088
9	6	0,075	19	21	0,263	29	13	0,163
10	7	0,088	20	19	0,238	30	16	0,200

Feito isso, calculamos a proporção média:

$$LC = \bar{p} = \frac{9+11+\dots+16}{80+80+\dots+80} = 0,1571$$

E, em seguida, calculamos o desvio-padrão:

$$\sigma_p = \sqrt{\frac{0,1571(1-0,1571)}{80}} = 0,0407$$

Podemos, assim, calcular os limites:

$$LCS = 0,1571 + 3 \times 0,0407 = 0,2791; \text{ e}$$

$$LCI = 0,1571 - 3 \times 0,0407 = 0,0350.$$

Feito isto, traçamos o gráfico de controle p :

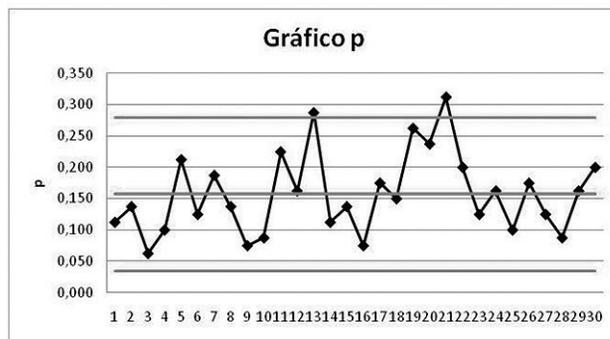


Figura 8.6: Gráfico de controle p para as 30 amostras.

Como você pode observar, há pontos fora dos limites, que são indícios de problemas no processo e precisaria ser iniciada uma investigação para identificar as causas e estabelecer ações de melhoria. Caso estivéssemos coletando dados iniciais, para estabelecer limites provisórios, deveríamos proceder como nos gráficos por variáveis (vide Aula 7): as amostras fora dos limites (amostras 13 e 21) seriam removidas e novos limites seriam calculados.

Veja como ficaria tal gráfico:

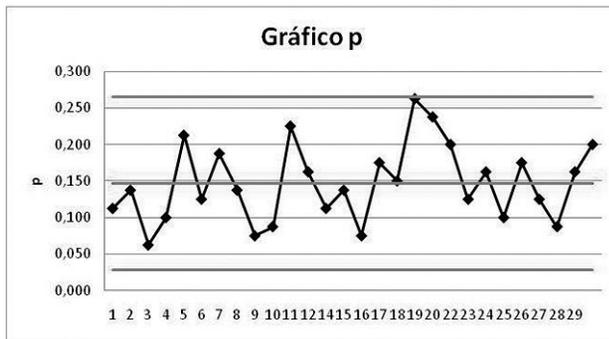


Figura 8.7: Gráfico de controle p, após a remoção das amostras 13 e 21.

Como não há mais pontos fora dos limites, os novos limites calculados poderiam ser estabelecidos como limites provisórios para o monitoramento e controle do processo. Se isso não acontecesse, isto é, se restassem pontos fora dos limites, o ciclo se repetiria até que não houvesse mais pontos nessa situação, desde que mantivéssemos um número mínimo de amostras aceitável para uso no processo em questão.

Gráfico np (quantidade de unidades defeituosas ou número de defeituosos)

É possível, também, utilizar o controle do processo com base na quantidade de unidades não conformes, ao invés da proporção delas (MONTGOMERY, 2001). “A carta np segue a mesma lógica da carta p, mas agora, ao invés da fração de não conformes, monitora-se o número de não conformes” (RIBEIRO; CATEN, 2012, p. 90). No entanto, apesar da similaridade entre os gráficos, eles não são utilizados com o mesmo objetivo (BESTERFIELD, 1990). “A carta np é mais apropriada quando:

a) o número de não conformes tem um maior significado e b) o tamanho dos subgrupos é sempre o mesmo (constante)” (RIBEIRO; CATEN, 2012, p. 91).

De acordo com Besterfield (1990) e Montgomery (2001), o gráfico np é mais fácil de ser compreendido e utilizado, pois os resultados (quantidade de unidades não conformes) são utilizados diretamente no gráfico, sem a necessidade de qualquer cálculo ou utilização de frações. Assim, ao invés de calcularmos a proporção de unidades defeituosas (por exemplo, 10%, ou 0,100), simplesmente fazemos a contagem destas.

Essa vantagem do gráfico np traz, porém, algumas exigências e limitações no seu uso, em especial, que o tamanho das amostras seja fixo. Sem isso, não teríamos uma base de comparação. Por exemplo, imagine a seguinte situação: uma empresa tem uma média histórica de aproximadamente 10 unidades defeituosas produzidas por turno de trabalho, mas, um dia, você recebe a informação de que somente três unidades defeituosas foram detectadas. Uma boa notícia, não é mesmo? Ou será que não?

Bem, imagine, por exemplo, que a empresa produz em média 100 unidades por turno, mas, naquele dia, houve um problema de suprimento e somente cinco unidades foram produzidas durante o turno. Obviamente, as três unidades defeituosas, de um total de somente cinco produzidas, representa um péssimo cenário, não é mesmo? Algo muito pior do que ter 10 defeituosas encontradas, quando são produzidas 100...

Desta forma, o gráfico np só pode ser utilizado para amostras do mesmo tamanho e o tamanho da amostra deve ser informado no gráfico, para que quem o visualize tenha uma referência (BESTERFIELD, 1990), como, por exemplo, que a quantidade média de unidades defeituosas $np = 10$ se refere a uma amostra de 100 unidades produzidas.

Para calcularmos os limites do gráfico np , utilizamos as seguintes equações:

$$LC = n\bar{p} = \frac{d_1 + d_2 + \dots + d_k}{k}$$

Sendo:

d_1, d_2 , etc. = quantidade de unidades não conformes na amostra 1, 2, etc.;

k = quantidade de amostras.

Com tal cálculo, identificamos a quantidade média de unidades defeituosas por amostra. Seguimos, então, para calcular os limites de controle da quantidade de unidades:

$$LCS = n\bar{p} + 3\sigma_{np}$$

$$LCI = n\bar{p} - 3\sigma_{np}$$

Sendo:

σ_{np} = desvio-padrão das amostras.

O desvio-padrão é calculado pela seguinte equação:

$$\sigma_{np} = \sqrt{n\bar{p}(1-\bar{p})}$$

E, obviamente...

$$\bar{p} = \frac{n\bar{p}}{n}$$

Compare tal equação com a que é utilizada para calcular o desvio-padrão no gráfico p : a diferença é que não há o denominador n , justamente por não estarmos trabalhando com a quantidade média de unidades não conformes (por isso, não dividimos por n). Desta forma, temos os seguintes limites para o gráfico p :

$$LCS = n\bar{p} + 3\sqrt{n\bar{p}(1-\bar{p})}$$

$$LCI = n\bar{p} - 3\sqrt{n\bar{p}(1-\bar{p})}$$



Costa, Epprecht e Carpinetti (2016) recomendam especial atenção para que os limites de controle *não* sejam números inteiros (o que pode acontecer por uma coincidência matemática), para evitar que algum ponto (isto é, a quantidade de unidades defeituosas em cada amostra) coincida exatamente com um dos valores de limite, pois ficaríamos na dúvida se tal ponto estaria fora ou dentro dos limites. Nesse sentido, os autores indicam ser uma boa prática “forçar” os limites: isso pode ser feito reduzindo ligeiramente o limite superior e/ou aumentar um pouco o limite inferior,

caso sejam números inteiros. Obviamente, se o limite inferior for zero, não precisamos ter essa preocupação, afinal, se ocorresse coincidência, seria de um ponto indicando zero unidade defeituosa.

Como você pode perceber, as fórmulas utilizadas no gráfico np são mais simples do que as utilizadas no gráfico p . Vamos trabalhar, então, com um exemplo de aplicação. Utilizaremos o mesmo exemplo adotado para o gráfico p , ou seja, dos eixos defeituosos apresentados por Ribeiro e Caten (2012, p. 88). Os dados replicados a seguir representam a quantidade de eixos defeituosos (d) em 30 amostras de tamanho $n = 80$.

Tabela 8.5: Quantidade de eixos defeituosos (d) em 30 amostras de tamanho $n = 80$

Amostra	d	Amostra	d	Amostra	d
1	9	11	18	21	25
2	11	12	13	22	16
3	5	13	23	23	10
4	8	14	9	24	13
5	17	15	11	25	8
6	10	16	6	26	14
7	15	17	14	27	10
8	11	18	12	28	7
9	6	19	21	29	13
10	7	20	19	30	16

Iniciamos, assim, os cálculos:

$$LC = n\bar{p} = \frac{9+11+\dots+16}{30} = 12,5667$$

$$\bar{p} = \frac{12,5667}{80} = 0,1571$$

$$LCS = 12,5667 + 3\sqrt{12,5667(1-0,1571)} = 22,3306$$

$$LCS = 12,5667 - 3\sqrt{12,5667(1-0,1571)} = 2,8028$$

E podemos traçar o gráfico np :

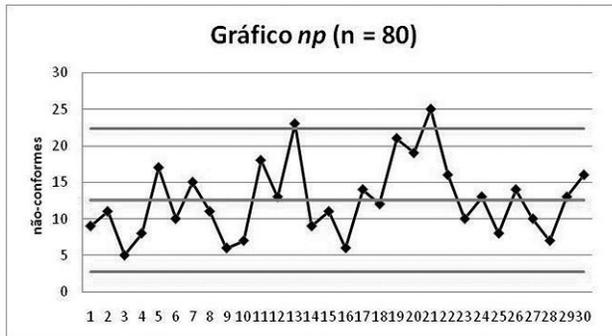


Figura 8.8: Gráfico de controle np .

Esse gráfico lhe parece familiar? Você já o viu antes?

Repare como ele é idêntico ao que traçamos como gráfico p : até mesmo os pontos fora dos limites identificados foram idênticos. Mas note que os gráficos estão em escalas diferentes: enquanto o eixo das ordenadas (eixo y) do gráfico p apresenta proporções, o gráfico np que acabamos de construir contém valores inteiros. Assim, como utilizamos a mesma base de dados e o tamanho da amostra era constante ($n = 80$), o formato dos gráficos é o mesmo, mas, na verdade, os valores do eixo das ordenadas do gráfico p são 80 vezes menores do que os do gráfico np (para $n = 80$). E, a exemplo do que aconteceu no gráfico p , há pontos fora dos limites (amostras 13 e 21) e, caso ainda estivéssemos na fase de definição de limites provisórios, deveríamos remover as amostras fora dos limites e calcular novos limites de controle.

Gráfico c (quantidade de defeitos, número de defeitos, ou número de não conformidades)

Há duas situações onde o gráfico c é tipicamente aplicável (GRÁFICO C, [201-]; RIBEIRO; CATEN, 2012):

- quando defeitos de diferentes tipos e origens podem ser encontrados nos produtos, e
- quando os defeitos estão distribuídos num fluxo mais ou menos contínuo de algum produto, como por exemplo: quantidade de falhas por área de tecido, quantidade de imperfeições por comprimento de pavimento, etc., sendo possível definir o número médio de defeitos.

De acordo com Besterfield (1990), o gráfico c pode ser utilizado para controlar e verificar o desempenho, dependendo dos custos envolvidos e dos benefícios esperados, de:

- uma única característica de qualidade;
- um grupo de características de qualidade;
- um/a peça/componente;
- um produto;
- uma quantidade de produtos;
- um operador;
- um centro de trabalho;
- um departamento;
- um turno;
- uma unidade fabril ou
- uma corporação.

Em produtos complexos como automóveis, computadores, geladeiras, etc., em que há a possibilidade de diferentes tipos de defeitos, o controle da quantidade de defeitos pode ser mais significativa do que simplesmente a quantidade de unidades defeituosas e, nesse caso, o uso do gráfico de controle c seria apropriado (COSTA; EPPRECHT; CARPINETTI, 2016).

Walpole et al. (2009) também recomendam seu uso quando as unidades são “grandes”, como, por exemplo a quantidade de defeitos existentes em 50 pés (aproximadamente 15 metros) de um encanamento manufaturado, em um rolo de tecido ou de papel, ou bolhas em uma lâmina de vidro. Cada exemplo desses representa o que Costa, Epprecht e Carpinetti (2016, p. 218) denominam *unidade de inspeção*, que é arbitrada, mas precisa ser definida para não haver o risco de interpretações errôneas dos valores coletados:

Num processo têxtil, a unidade de inspeção pode ser certo número de metros de tecido (por exemplo, 100 m, 50 m ou 500 m); na produção de chapas em rolo, como aquelas fabricadas pela CSN ou Cosipa, a unidade de inspeção pode ser definida como 10, 100 ou mesmo 1.000 m de chapa; na produção de geladeiras ou automóveis, a unidade de inspeção pode ser 1, 2, 4 ou qualquer

número de unidades do produto. Se o processo estiver em controle (isento de causas especiais), é de se esperar que as não conformidades ocorram de forma aleatória e com baixa frequência.



É importante destacar que, ainda que no gráfico *c* lidemos com a quantidade de defeitos, a definição da unidade de inspeção pode fazer com que o tamanho da amostra não seja inteiro, como no exemplo apresentado por Costa, Epprecht e Carpinetti (2016): se a unidade de inspeção for definida como sendo de 200 m de tecido, mas o tamanho da amostra for de 100 m de tecido, o tamanho da amostra seria 0,5, devido à conversão para respeitar a unidade de medida da unidade de inspeção.

O gráfico *c* é baseado na distribuição de Poisson e, por conta disso, duas condições são mandatórias (BESTERFIELD, 1990):

1. A contagem média de não conformidades deve ser muito menor do que a quantidade possível de não conformidades (ex: faturas erradas emitidas por um fabricante de automóveis);
2. Ocorrências são independentes: a ocorrência de uma não conformidade não aumenta ou diminui a probabilidade da próxima ocorrência ser uma não conformidade (ex: erros de digitação em uma folha de uma tese).



A distribuição de Poisson é uma distribuição de probabilidade de variáveis aleatórias discretas que descreve a probabilidade de eventos independentes, que ocorrem aleatoriamente, mas a uma taxa média definida em longo prazo, ocorrerem num certo período de tempo (ou qualquer outra dimensão contínua, como distância, área ou volume) (KAZMIER, 2007; BECKER, 2015).

Apesar de sua semelhança com a distribuição binomial, ela se difere no sentido de que, enquanto a distribuição binomial define um limite superior na contagem (o número de eventos observados não pode ser maior do que o número de ensaios realizados), a distribuição de Poisson, dentro do seu espaço de observação finito, não estabelece qualquer limite máximo (por exemplo, uma mesa telefônica pode receber uma quantidade enorme de chamadas em determinado intervalo de tempo (MONTGOMERY; RUNGER, 2009; MINITAB, 2017b)).

Isso ocorre porque a distribuição binomial é afetada pelo tamanho da amostra e pela probabilidade de ocorrência, ao passo que a distribuição de Poisson é afetada apenas pela taxa (ou proporção) média de ocorrência. Ou seja, a distribuição de Poisson é utilizada quando o número de ocorrências discretas (n) é muito grande e a probabilidade de ocorrência (p) é baixa, tratando-se, portanto de eventos raros, tais como erros de digitação, acidentes aeronáuticos, etc.

Seus pressupostos são (DISTRIBUIÇÃO DE POISSON, [201-]; LOZADA, 2017; MINITAB, 2017b):

- os dados são contagens de eventos (inteiros não negativos com nenhum limite superior);
- todos os eventos são independentes;
- as ocorrências são aleatórias, tendo a mesma probabilidade no intervalo considerado;
- a taxa média não muda sobre o período de interesse;
- a probabilidade de dois ou mais eventos ocorrerem simultaneamente tende a zero.

Atendidas as condições, podemos calcular os limites do gráfico c , que, a exemplo do gráfico np , exige que o tamanho das amostras seja constante. Utilizamos, então, as seguintes equações:

$$LC = \bar{c} = \frac{c_1 + c_2 + \dots + ck}{k}$$

Onde

\bar{c} = quantidade média de não conformidades (defeitos);

$c_1, c_2, \text{ etc.}$ = quantidade de não conformidades na amostra 1, 2, etc. e

k = quantidade de amostras



Na área industrial, a quantidade de amostras geralmente varia de 10 a 50, dependendo da dificuldade e do tipo de produto ou processo que se deseja controlar (PEINADO; GRAEML, 2007), com tamanho normalmente $n < 10$ (os planos de amostragem serão discutidos nas Aulas 11 e 12).

$$LCS = \bar{c} + 3\sigma_c$$

$$LCS = \bar{c} - 3\sigma_c$$

Sendo:

σ_c = desvio-padrão das amostras.

O desvio-padrão é calculado pela seguinte equação:

$$\sigma_c = \sqrt{\bar{c}}$$

Vamos praticar, utilizando um exemplo apresentado por Ribeiro e Caten (2012, p.93), referente à quantidade de defeitos de pintura (não conformidades), observados na pintura da lataria de ônibus, mostrados a seguir.

Tabela 8.6: Defeitos de pintura na lataria de ônibus

Lataria	c	Lataria	c	Lataria	c	Lataria	c
1	4	6	12	11	1	16	6
2	0	7	9	12	7	17	17
3	8	8	5	13	5	18	13
4	14	9	9	14	15	19	8
5	4	10	21	15	4	20	11

Iniciamos, então, os cálculos (neste exemplo, temos $n = 1$):

$$LC = \bar{c} = \frac{4+0+\dots+11}{20} = 8,65$$

$$LCS = 8,65 + 3\sqrt{8,65} = 17,473$$

$$LCS = 8,65 - 3\sqrt{8,65} = -0,173$$

Observe que, como encontramos um limite inferior menor que zero, utilizaremos o valor zero como limite. Construímos, então, o gráfico c :

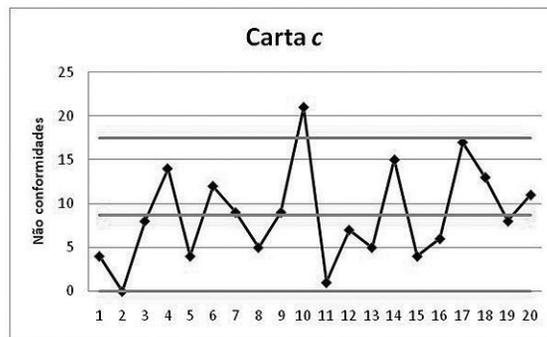


Figura 8.9: Carta c .

Observe que há um ponto fora dos limites (lateria 10) e, como já discutido antes, precisaria ser investigada a razão. Caso estivéssemos ainda definindo os limites provisórios, deveríamos descartar tal amostra e recalculamos os limites.

Vamos aproveitar o exemplo e analisar, também, um aspecto interessante: repare como o ponto 17 está próximo do limite superior. Ele reflete a quantidade de 17 defeitos, contra um limite superior de 17,473, estando, portanto, dentro dos limites. Isso mostra o quanto importante é nos certificarmos de que os limites não coincidam com valores inteiros, como discutido anteriormente: imagine, por exemplo, que o limite superior deste gráfico fosse de exatamente 17 defeitos. Surgiria a dúvida: o ponto que apresentasse o valor de 17 estaria dentro ou fora do limite?

Gráfico *u* (defeitos por unidade, número de defeitos por unidade de inspeção ou número de não conformidades por unidade de inspeção)

Montgomery (2001) expõe que o controle da quantidade de defeitos ou não conformidades é mais informativo do que as proporções de não conformidades, por usualmente existirem diferentes tipos de não conformidades. Ao analisarmos estas não conformidades por estrato (vide o conceito e as aplicações de estratificação na Aula 3), podemos utilizar ferramentas como o diagrama de Pareto (vide Aula 4), para identificar as causas mais frequentes; o diagrama de causa e efeito (vide Aula 5), para auxiliar na identificação das causas-raiz, e outras ferramentas mais, para controle e melhoria da qualidade.

No entanto, como o gráfico *c* exige que as amostras tenham o mesmo tamanho, seu uso algumas vezes traz dificuldades. Por exemplo, se queremos controlar a quantidade de defeitos em rolos de tecido, com cada amostra sendo de um rolo e variando tais rolos na metragem de um para o outro, o gráfico *c* não seria adequado (COSTA; EPPRECHT; CARPINETTI, 2016): precisamos recorrer, assim, a um gráfico de controle que lide com proporções de não conformidades, da mesma forma que o gráfico *p* controlar a proporção não conforme de unidades.

O gráfico de controle *u* monitora o número de não conformidades por unidade produzida, sendo similar ao gráfico *c*, exceto pelo fato de que a quantidade de não conformidades é expressa em relação a cada unidade (ou seja, divide-se pelo tamanho da amostra *n*) (RIBEIRO; CATEN, 2012). Ou seja, “pode ser uma alternativa ao gráfico *c*, quando as amostras não têm o mesmo tamanho” (CHRISTO, 2017, p. 13).

Para calcularmos os limites do gráfico *u*, utilizamos as seguintes equações:

$$LC = \bar{u} = \frac{c_1 + c_2 + \dots + ck}{n_1 + n_2 + \dots + nk}$$

Sendo:

c_1, c_2, \dots = quantidade de não conformidades na amostra 1, 2, etc.;

n_1, n_2, \dots = tamanho da amostra 1, 2, etc.

$$LCS = \bar{u} + 3\sigma_{ui}$$

$$LCI = \bar{u} - 3\sigma_{ui}$$

Sendo:

σ_{ui} = desvio-padrão da amostra.

A exemplo do gráfico p , no gráfico u , “a linha média é fixa e os limites variam conforme o tamanho da amostra (COSTA; EPPRECHT; CARPINETTI, 2016, p.225). Desta forma, o desvio-padrão para o gráfico de controle u é dado pela seguinte equação:

$$\sigma_{ui} = \sqrt{\frac{\bar{u}}{n}}$$

Desta forma, temos os seguintes limites para o gráfico p :

$$LCS = \bar{u} + 3\sqrt{\frac{\bar{u}}{n}}$$

$$LCI = \bar{u} - 3\sqrt{\frac{\bar{u}}{n}}$$

Como em gráficos similares, caso o cálculo do limite inferior resulte em um valor negativo, utilizamos zero como limite inferior de controle.

Vamos exercitar a construção do gráfico de controle u utilizando o exemplo de Ribeiro e Caten (2012, p. 95-96), referente à quantidade de defeitos superficiais observados em sapatos, como mostrado a seguir.

Tabela 8.7: Quantidade de defeitos superficiais observados em sapatos

Lote	N. de unidades	N. de NC
1	10	13
2	10	11
3	10	8
4	12	20
5	12	15
6	10	10
7	10	13
8	12	19
9	8	15
10	8	9

Iniciamos, então, os cálculos: primeiramente, precisamos calcular o u para cada amostra, dividindo a quantidade de não conformidades pelo tamanho da amostra. Segue a tabela com a coluna adicional com tais valores.

Tabela 8.8: Cálculo da quantidade de não conformidades dividida pelo tamanho da amostra

Lote	N. de unidades	N. de NC	N. de NC/unid
1	10	13	1,30
2	10	11	1,10
3	10	8	0,80
4	12	20	1,67
5	12	15	1,25
6	10	10	1,00
7	10	13	1,30
8	12	19	1,58
9	8	15	1,88
10	8	9	1,13

Em seguida, calculamos os demais elementos do gráfico, como segue.

$$LC = \bar{u} = \frac{13+11+\dots+9}{10+10+\dots+8} = 1,304$$

Já quanto aos limites, eles variarão dependendo do tamanho da amostra. Vamos mostrar o cálculo do primeiro lote:

$$LCS = 1,304 + 3\sqrt{\frac{1,304}{10}} = 2,3872$$

$$LCI = 1,304 - 3\sqrt{\frac{1,304}{10}} = 0,2206$$

Segue a tabela, agora com os limites calculados para cada lote.

Tabela 8.9: Limites calculados para cada lote

Lote	No. de unidades	No. de NC	No. de NC/unid	LCS	LCI
1	10	13	1,30	2,3872	0,2206
2	10	11	1,10	2,3872	0,2206
3	10	8	0,80	2,3872	0,2206
4	12	20	1,67	2,2928	0,3150
5	12	15	1,25	2,2928	0,3150
6	10	10	1,00	2,3872	0,2206
7	10	13	1,30	2,3872	0,2206
8	12	19	1,58	2,2928	0,3150
9	8	15	1,88	2,5151	0,0928
10	8	9	1,13	2,5151	0,0928

Alternativamente, podemos calcular os limites de forma conservadora, utilizando o “pior caso”, ou seja, a maior amostra (n = 12): nesse caso, os limites seriam LCS = 2,3872 e LCI = 0,3150. Ao fazer isso, caso surjam pontos fora dos limites, devemos adotar a mesma recomendação para o gráfico *p*: os limites devem ser recalculados para tais pontos separadamente, para nos certificarmos de serem mesmo pontos “fora dos limites” ou não.

Veja a seguir o gráfico u , no qual foram adicionados tantos os limites reais quanto os limites “mais apertados” (que têm o sufixo “12”, em referência ao tamanho da amostra utilizada).

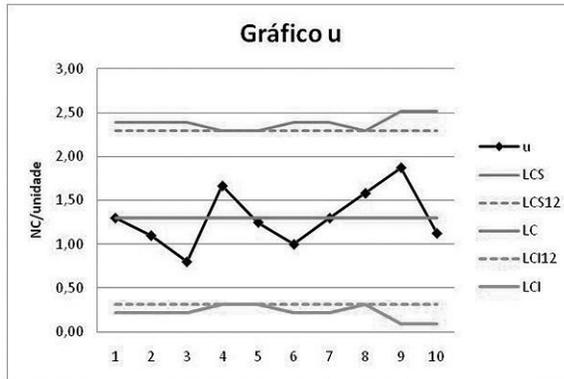


Figura 8.10: Gráfico u , com a adição dos limites reais e dos limites “mais apertados” (que têm o sufixo “12”, em referência ao tamanho da amostra utilizada)

Observe que, nesse exemplo, não precisaríamos sequer ter calculado os limites para cada amostra, visto que, mesmo com limites mais severos, não houve qualquer ponto “fora” deles. Outra forma de apresentar os limites do gráfico u é na forma de “degraus”, como mostrado a seguir.

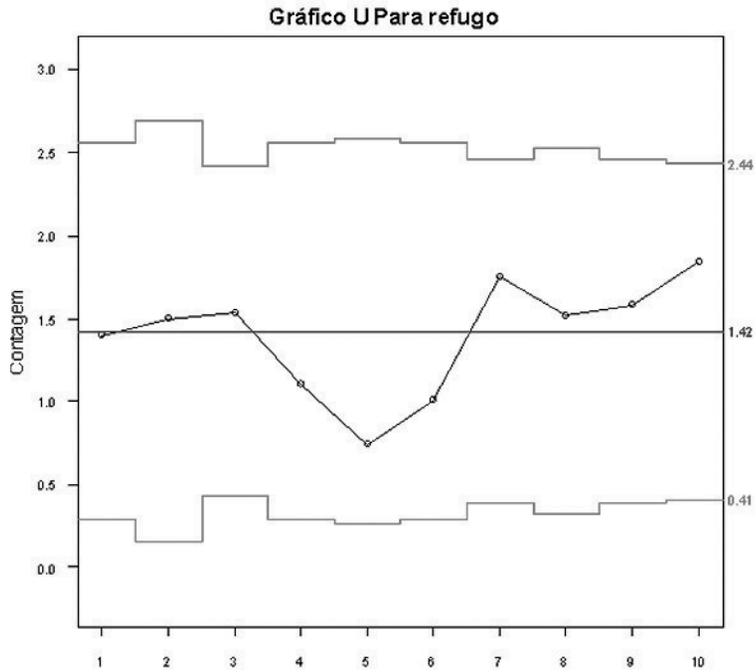


Figura 8.11: Gráfico de controle u, referente a amostras de tamanhos diferentes. Como você pode observar, similarmente ao gráfico p, os limites de controle não são constantes, variando em função do tamanho das amostras. Fonte: Gráfico u, [201-].

═══════════════════════ **Atividade** ════════════════════════

Atende aos objetivos 1 e 2

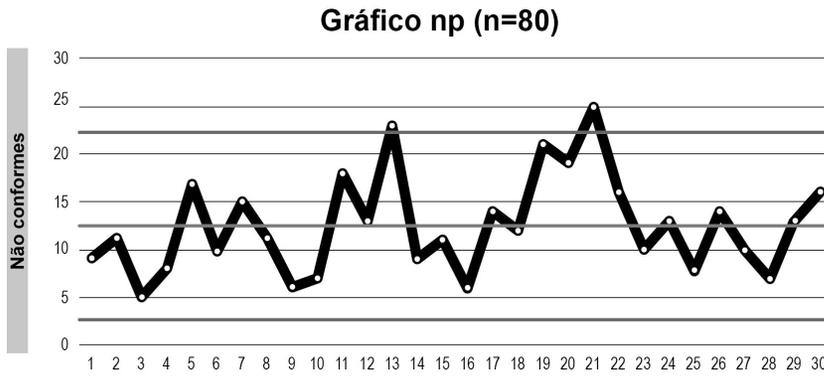
No conteúdo desta aula, você aprendeu como construir e analisar gráficos de controle por atributos. Viu, também, que, quando iniciamos o controle de um processo, por não termos um histórico de resultados, estabelecemos limites provisórios: para isso, descartamos amostras que indiquem a ocorrência de causas especiais e recalculamos os limites. Isso foi exemplificado no trecho em que você estudou o gráfico de controle *p*.

a) Retorne ao exemplo do gráfico *np*, que apresentou pontos fora dos limites e assumo que se tratava de dados coletados para estabelecer limites provisórios. Assim sendo, descarte as amostras pertinentes e recalcule os limites que caracterizem um processo submetido tão-somente a causas comuns.

b) Idem para o exemplo do gráfico *c*.

Resposta comentada

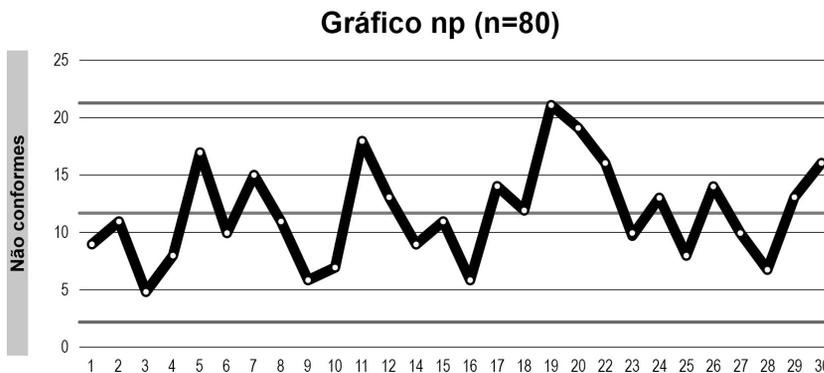
a) O gráfico *np*, que é replicado a seguir, apresentou duas amostras (13 e 21) fora dos limites.



Calculamos, então, os valores dos limites, utilizando as equações que você estudou, e encontramos os seguintes valores:

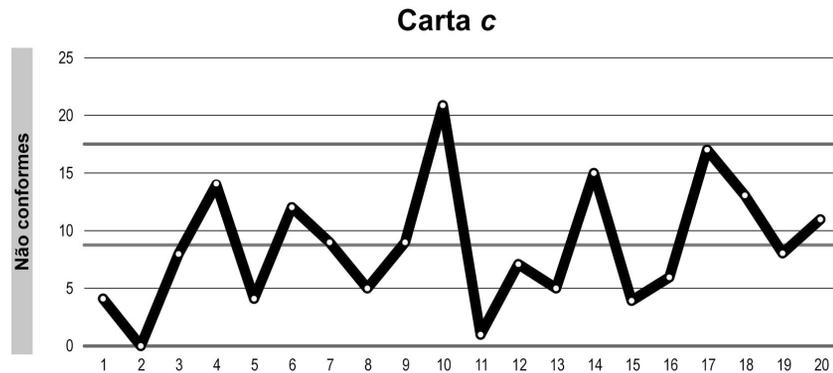
np =	11,75
n =	80
p =	0,1469
DP =	3,1661
LCS =	21,2483
LCI =	2,2517

De posse de tais valores, podemos construir o gráfico *np*:



Não havendo mais pontos fora dos limites (a amostra 19, com valor 21, está abaixo do limite superior de 21,2483) e, assim sendo, os limites $LCS = 21,2483$ e $LCI = 2,2517$ podem ser estabelecidos para controlar o processo.

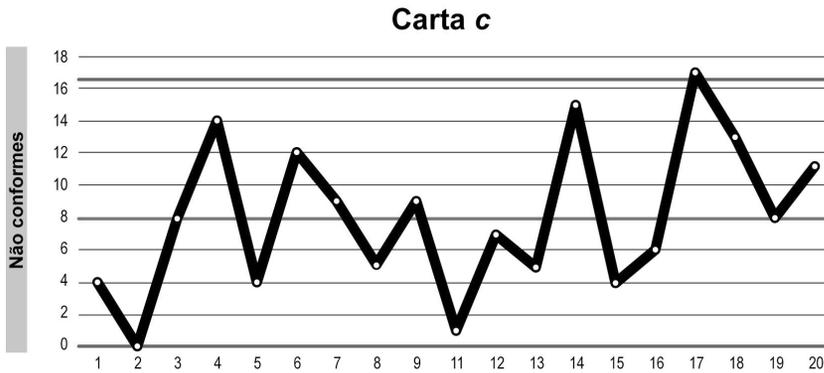
b) No caso do gráfico *c*, que é replicado a seguir, temos a amostra 10 acima do limite superior.



Descartamos a citada amostra e recalculamos os limites:

$c =$	8,0000
$DP =$	2,8284
$LCS =$	16,4853
$LCI =$	-0,4853

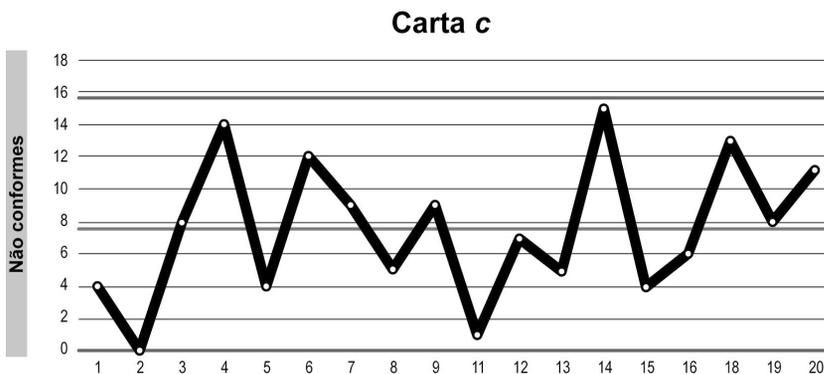
Como o limite inferior calculado é negativo, utilizaremos zero como limite inferior e construímos o gráfico de controle *c*:



Como você pode perceber, com os novos limites ainda permanece uma amostra acima do limite superior aceitável: a amostra 17, com valor 17, está acima do limite 16,4853. Devemos, então, reiniciar o ciclo, descartando a referida amostra e recalculando os limites.

c =	7,5000
DP =	2,7386
LCS =	15,7158
LCI =	-0,7158

E traçamos o novo gráfico:



Nesta nova situação, não há mais pontos fora dos limites. Conseguimos, então, estabelecer os limites para o controle do processo, quais sejam: $LCS = 15,7158$ e $LCI = 0$.

Conclusão

Os gráficos de controle por atributos abrem um leque adicional do âmbito do controle e melhoria da qualidade: ainda que não sejam tão precisos quanto os gráficos por variáveis, por lidarem tão-somente com “resultados finais” (defeitos e unidades defeituosas), permitem prover uma visão geral, mais ampla sobre o que é produzido, visto que eles indicariam consequências de problemas em componentes e medidas diversas.

Desta forma, como não é viável em termos de tempo e custos controlar todas as medidas de todos os componentes de um produto, os gráficos de controle por atributos se tornam uma excelente forma de detecção de problemas, a partir do que as investigações e a identificação das causas-raiz, utilizando ferramentas como o diagrama de causa e efeito, o diagrama de Pareto, histogramas, etc., permite que possamos atuar de forma efetiva no controle e melhoria da qualidade.

Resumo

Para o controle e melhoria da qualidade, é comum a utilização de ferramentas, quais sejam:

- estratificação
- folha de verificação
- diagrama de dispersão
- gráfico de Pareto
- diagrama de causa e efeito
- histograma
- gráficos de controle

Os gráficos de controle, que podem ser aplicados a variáveis contínuas (ex.: medidas de diâmetro, peso, etc.), na forma dos gráficos \bar{X} -s e

\bar{X} -R, têm nos gráficos por atributos outra vertente: ao invés de medidas contínuas, monitoramos as condições de peças ou produtos, no sentido de conterem alguma forma de não conformidade (defeitos).

Nesse sentido, os gráficos de controle por atributos podem ser utilizados para monitorar a quantidade de defeitos (não conformidades) ou a quantidade de unidades defeituosas (não conformes). Também podem ser utilizados para monitorar (nos dois casos) a proporção de não conformidades e não conformes. O quadro a seguir apresenta um resumo dos quatro tipos de gráfico de controle por atributos mais comuns.

Tabela 8.10: Para que serve cada gráfico

Tipo de gráfico	O que é “contado”:	
	Defeitos (não conformidades)	Defeituosos (não conformes)
Tamanho das amostras		
=	c – quantidade de defeitos	np – quantidade de unidades defeituosas
= ou ≠	u – defeitos/unidade	p – proporção defeituosa

Quando utilizamos os gráficos u e p , caso o tamanho das amostras varie (o que não é aceitável nos gráficos c e np), os limites de controle não são constantes, como mostrado na **Figura 8.4**, que é replicada a seguir (trata-se de um gráfico de controle p).

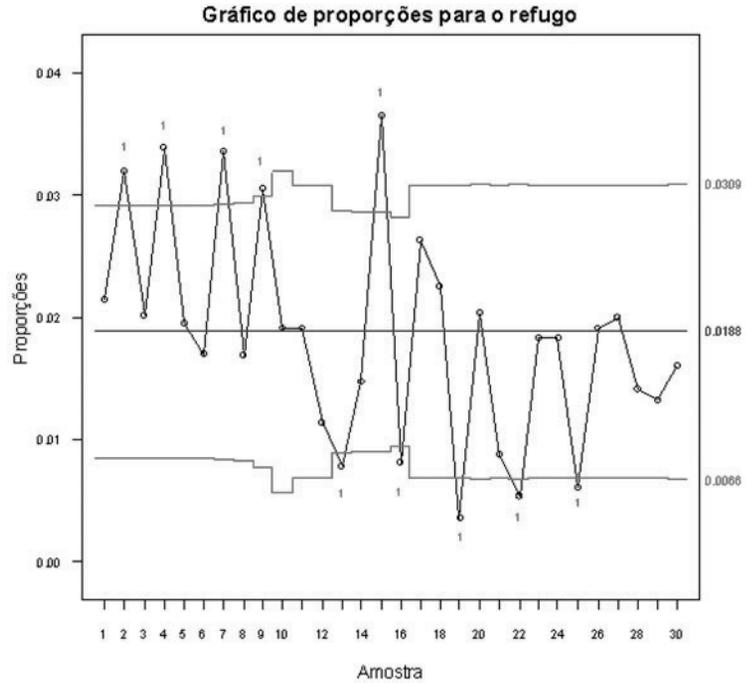


Figura 8.4: Gráfico de controle p, referente a amostras de tamanhos diferentes. Como você pode observar, os limites de controle não são constantes: eles variam em função do tamanho das amostras. A análise visual, no entanto, permanece como vimos até o momento: valores acima do limite superior ou abaixo do limite inferior são indicativos de potenciais problemas.

Fonte: Gráfico p, [201-].

A forma de interpretação dos resultados dos gráficos por atributos é a mesma dos gráficos por variáveis: pontos fora dos limites seriam indicativos de causas especiais e requerem investigação e ações sobre o processo. Além disso, a exemplo dos gráficos por variáveis, caso a coleta de dados seja inicial, visando estabelecer limites provisórios, as amostras que levarem a pontos fora dos limites devem ser descartadas e os limites recalculados, de tal forma que tenhamos estabelecidos limites que caracterizem processos sujeitos somente a causas comuns.

Leitura recomendada

EPPRECHT, Eugenio Kahn; LEIRAS, Adriana; COSTA, Antonio Fernando Branco. Planejamento do controle estatístico de processos com baixa fração não conforme restrito a amostras pequenas. *Prod.*, São Paulo,

v. 17, n. 1, p. 139-150, abr. 2007. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-65132007000100010&lng=en&nrm=iso. Acesso em: 6 fev. 2019.

Informação sobre a próxima aula

Na próxima aula, continuaremos os estudos dos gráficos de controle, com foco na interpretação de cartas de controle, que vai além da verificação da existência de pontos fora dos limites, bem como na escolha do tipo de gráfico a ser utilizado.

Referências

BECKER, João Luiz. *Estatística básica: transformando dados em informação*. Porto Alegre: Bookman, 2015.

BESTERFIELD, Dale H. *Quality Control*. 3. ed. Englewood Cliffs: Prentice-Hall, 1990.

CHRISTO, E. S. *Aula 8 – Ferramentas para o controle da qualidade*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 8), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=11>. Acesso em: 25 fev. 2019.

COSTA, Antônio Fernando Branco; EPPRECHT, Eugenio Kahn; CARPINETTI, Luiz César Ribeiro. *Controle estatístico de qualidade*. 2. ed. São Paulo: Atlas, 2016.

DISTRIBUIÇÃO DE POISSON. *Portal Action*, [201-]. Disponível em <<http://www.portalaction.com.br/probabilidades/52-distribuicao-de-poisson>>. Acesso em 04 Fev. 2019.

GARVIN, D.A. What Does “Product Quality” Really Mean? *MIT Sloan Management Review*, outono 1984, 15 out. 1984. Disponível em: <https://sloanreview.mit.edu/article/what-does-product-quality-really-mean/>. Acesso em: 16 maio 2018.

GARVIN, D. A. *Gerenciando a qualidade*. 3. ed. Rio de Janeiro: Quality Mark, 2002.

GRÁFICO C – Número de defeitos por amostra. *Portal Action*, [201-]. Disponível em <<http://www.portalaction.com.br/controle-estatistico-do-processo/53-grafico-c-numero-de-defeitos-por-amostra>>. Acesso em 04 Fev. 2019.

GRÁFICO P – Proporção ou fração de defeituosos. *Portal Action*, [201-]. Disponível em <<http://www.portalaction.com.br/controle-estatistico-do-processo/51-grafico-p-proporcao-ou-fracao-de-defeituosos>>. Acesso em 01 Fev. 2019.

GRÁFICO U – Taxa de defeitos por unidade. *Portal Action*, [201-]. Disponível em <<http://www.portalaction.com.br/controle-estatistico-do-processo/54-grafico-u-taxa-de-defeitos-por-unidade>>. Acesso em 04 Fev. 2019.

KAZMIER, Leonard J. *Estatística aplicada à administração e economia*. 4. ed. Porto Alegre: Bookman, 2007.

LOZADA, Gisele. *Controle estatístico de processos*. Porto Alegre: Sagah, 2017.

MINITAB. *Distribuição Bernoulli*, 2017a. Disponível em: <https://support.minitab.com/pt-br/minitab/18/help-and-how-to/probability-distributions-and-random-data/supporting-topics/distributions/bernoulli-distribution/>. Acesso em: 4 fev. 2019.

MINITAB. *Distribuição de Poisson*, 2017b. Disponível em: <https://support.minitab.com/pt-br/minitab/18/help-and-how-to/probability-distributions-and-random-data/supporting-topics/distributions/poisson-distribution/>. Acesso em: 4 fev. 2019.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. 4. ed. New York: John Wiley & Sons, 2001.

MONTGOMERY, D. C.; RUNGER, G. C. *Estatística aplicada e probabilidade para engenheiros*. 4. ed. Rio de Janeiro: LTC, 2009.

PEINADO, Jurandir & GRAEML, A. Reis. *Administração da produção: operações industriais e de serviços*. Curitiba: UnicenP, 2007.

RAMOS, Edson M. L. S.; ALMEIDA, Silvia dos Santos de; ARAÚJO, Adrilayne dos Reis. *Controle estatístico da qualidade*. Porto Alegre: Bookman, 2013.

RIBEIRO, José Luis Duarte; CATEN, Carla Schwengber ten. *Controle estatístico do processo: cartas de controle para variáveis, cartas de*

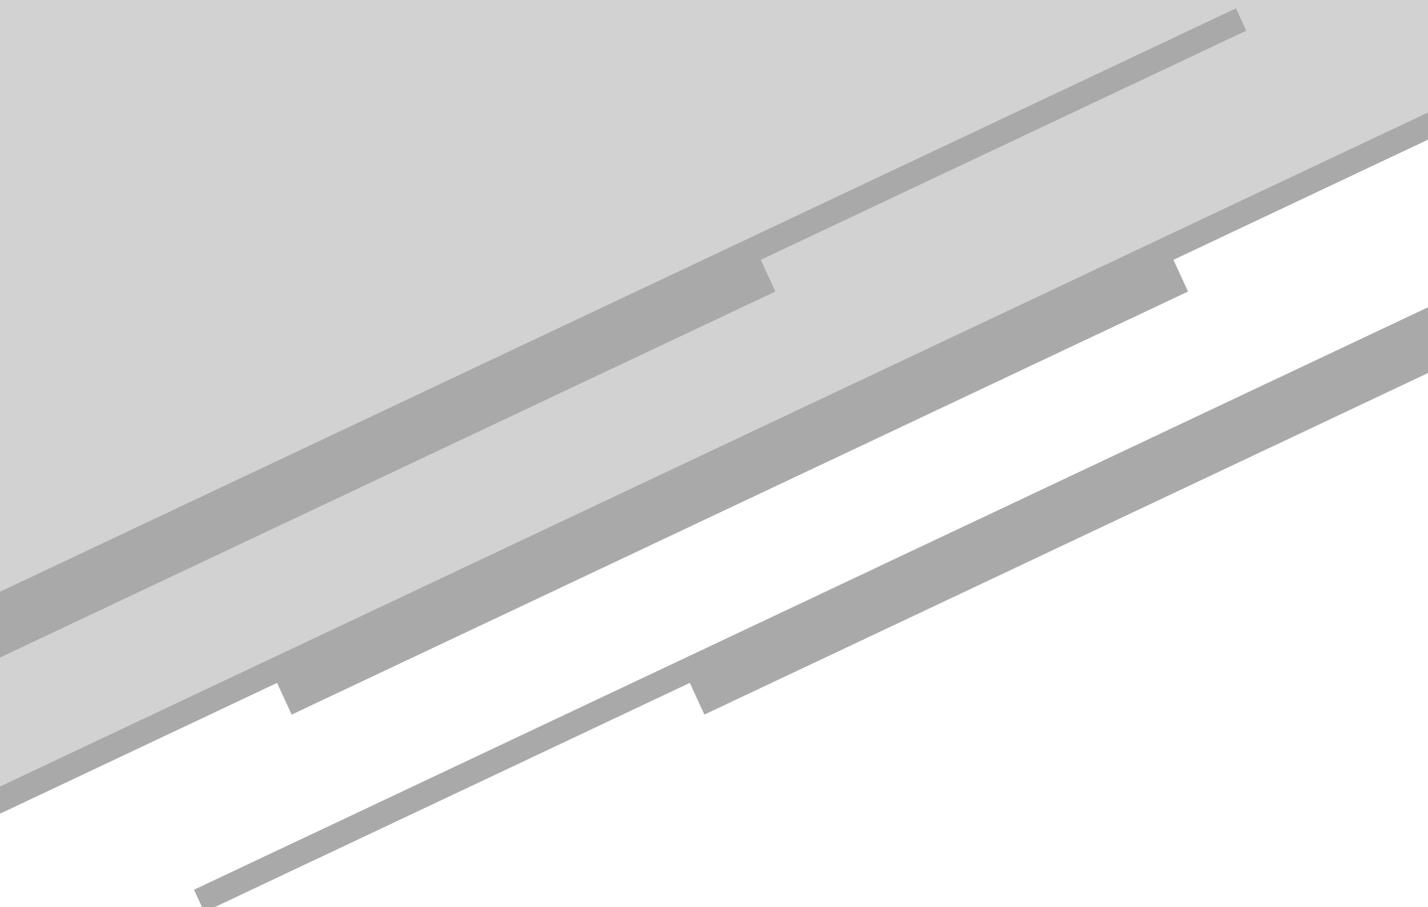
controle para atributos, função de perda quadrática, análise de sistemas de medição. Série monográfica Qualidade. Porto Alegre: FEENG/UFRGS – Fundação Empresa Escola de Engenharia da UFRGS - Universidade Federal do Rio Grande do Sul, 2012.

WALPOLE, Ronald E.; MYERS, Raymond H.; MYERS, Sharon, L.; YE, Keying. *Probabilidade & estatística para engenharia e ciências*. 8. ed. São Paulo: Pearson Prentice Hall, 2009.

ZIBETTI, André. *Distribuição binomial*. Universidade Federal de São Carlos – UFSC. Disponível em: <https://www.inf.ufsc.br/~andre.zibetti/probabilidade/binomial.html>. Acesso em: 4 fev. 2019.

Aula 9

Ferramentas para o controle da qualidade:
gráfico de controle (continuação)



Meta

Apresentar as sete ferramentas estatísticas principais usadas para o controle da qualidade.

Objetivos

Esperamos que, ao final deste conteúdo, você seja capaz de:

1. saber como utilizar as sete ferramentas estatísticas mais comuns no controle da qualidade de um processo;
2. conhecer o gráfico de controle, ou as cartas de controle por variáveis e por atributos, que representam uma das ferramentas mais utilizadas no controle da qualidade.

Pré-requisitos

Funções estatísticas e distribuição normal, ciclo PDCA, causas comuns e causas especiais, gráficos \bar{X} -R, \bar{X} -s, p, np, c e u, conteúdos abordados nas aulas anteriores.

Introdução

A lógica dos gráficos de controle, que se baseia em dados históricos e ferramentas estatísticas para identificar o comportamento esperado de processos e, desta forma, permitir identificar variações ocorridas em tais processos (que poderiam implicar problemas diversos), estabelece variações aceitáveis nos resultados dos processos, isto é limites que indicam se o processo está submetido somente a causas comuns ou se há causas especiais (as quais caracterizariam o processo como fora de controle).

No entanto, a verificação dos limites nem sempre é suficiente para apurar a estabilidade de um processo: padrões de distribuição dos valores nos gráficos podem indicar eventuais problemas, mesmo que os limites não tenham sido ultrapassados.

É isso que você estudará aqui: você continuará estudando o gráfico de controle, mas, agora, aprendendo sobre formas de analisar tais distribuições, sejam elas em gráficos por variáveis ou por atributos. Bons estudos!

A utilização dos gráficos de controle permitiu expandir as análises voltadas à manutenção e melhoria da qualidade: tais gráficos nos permitem identificar indícios de problemas antes mesmo que eles aconteçam ou que causem problemas e danos em peças, produtos e instalações.

A mera constatação de que algo no processo está diferente do que era antes nos sinaliza que os resultados da execução de tais processos podem gerar produtos não conformes. Isso acontece quando identificamos pontos nos gráficos que estão fora dos limites estabelecidos, como mostrado a seguir.

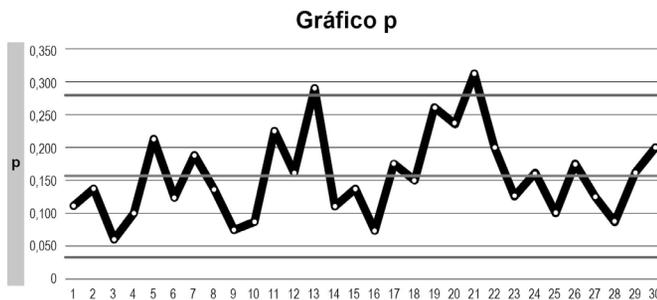


Figura 9.1: Gráfico de controle p (proporção de itens defeituosos). Ainda que desejemos que problemas e defeitos não ocorram, se dispomos de um histórico de ocorrência destes, a expectativa é a de que, enquanto nada for feito, tenhamos aproximadamente a mesma proporção de itens não conformes ocorrendo. Se variações além dos limites esperados ocorrem (seja para mais ou para menos), isso é um indicativo de que “algo diferente” ocorreu no processo, ou seja, que ele está fora de controle.

Como você estudou na Aula 6, é normal que aconteçam variações, pois os processos estão submetidos às denominadas causas comuns (também chamadas de causas aleatórias), isto é, heterogeneidade nos materiais, variações na temperatura, vibração, etc. E isso é o que os gráficos de controle nos mostram dentro dos seus limites. Por outro lado, variações mais intensas ocorreriam por conta das chamadas causas especiais (também conhecidas como causas atribuíveis ou causas assinaláveis), como, por exemplo, o desgaste excessivo ou a quebra de uma ferramenta, o afrouxamento de um componente em uma máquina de produção, etc. E tais variações seriam evidenciadas por pontos fora dos limites nos gráficos de controle.

Observe, por exemplo, o gráfico de um processo que está sob controle:

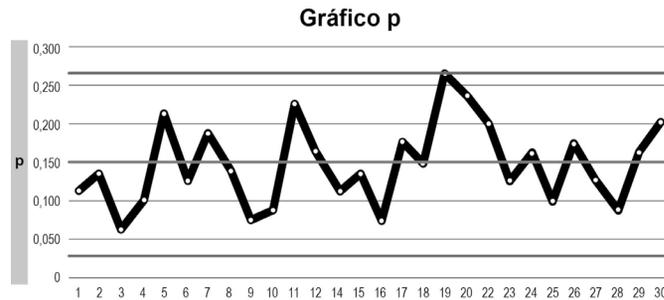


Figura 9.2: Gráfico de controle p (proporção de itens defeituosos). Por mostrar que as variações ocorrem, embora dentro dos limites estabelecidos, podemos inferir que o processo está sob controle, isto é, submetido somente a causas comuns.

Mas, é preciso ter em mente que, ainda que “estar dentro dos limites” seja a regra principal quando analisamos gráficos de controle, a característica esperada de aleatoriedade nos valores oriundos de um processo submetido tão-somente a causas especiais, leva em consideração outros aspectos.

Veja, por exemplo, o gráfico a seguir. Apesar de todos os pontos estarem dentro dos limites de controle, você percebe algo estranho no gráfico? Vê alguma coisa que parece violar a ideia de aleatoriedade e/ou de que não aconteceu algo de “diferente” no processo?

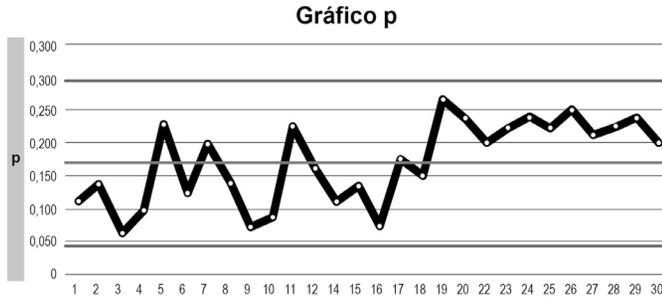


Figura 9.3: Gráfico de controle p (proporção de itens defeituosos). Ainda que todos os pontos estejam dentro dos limites de controle, podemos dizer que o processo monitorado por esse gráfico está sob controle? Avalie-o.

Você reparou que os últimos pontos ficaram menos dispersos do que os iniciais? Reparou, também, que a proporção dos itens defeituosos aumentou, isto é, os últimos pontos estão consistentemente acima da média? Você se sentiria confortável em afirmar que o processo está sob controle, somente baseado no fato de que não há pontos acima do limite? Ou a sua percepção é a de que “algo aconteceu” no processo, pois o gráfico de controle “está estranho”? Bem, se sua resposta foi a de que o processo não parece estar sob controle, sua percepção está correta: de fato, tal gráfico nos mostra um processo que está submetido a causas especiais e, conseqüentemente, deve ser iniciada uma investigação para apurar quais são estas causas.

Mas não podemos pautar nossas análises somente em “achar estranho”: é muito subjetivo. É necessário termos regras que nos apontem situações em que podemos fazer tal tipo de inferência, de tal forma que nosso julgamento não tenha tanta subjetividade. Vejamos quais são estas regras e compreender como elas são definidas, isto é, qual a lógica de análise dos gráficos de controle que vão além dos limites de controle.

Aleatoriedade dos dados

Como você viu na Aula 6, em um processo submetido somente a causas comuns, a expectativa é a de que tenhamos valores ao redor de uma medida central (média) e que a dispersão nos valores seja equivalente ao de uma distribuição normal.

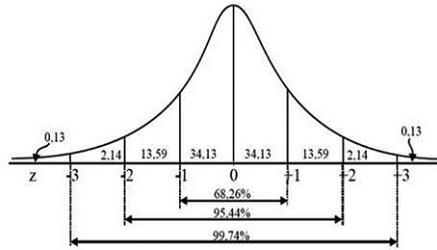


Figura 9.4: Curva normal. A representação de uma distribuição normal mostra uma concentração de valores ao redor do valor central (média): 68,26% das ocorrências dentro de uma faixa de ± 1 desvio-padrão; 95,44% na faixa de ± 2 desvios-padrões e 99,74% na faixa de ± 3 desvios-padrões. Desta forma, somente uma proporção muito pequena (aproximadamente 0,27%) das ocorrências estaria muito afastada do valor central, isto é, além dos ± 3 desvios-padrões.

Fonte: sondagens e estudos de opinião (2012).

Desta forma, como também visto nas Aulas 6 e 7, existe a possibilidade de, mesmo com um processo sob controle, termos pontos fora dos limites nos gráficos de controle. Mas a probabilidade é muito pequena (0,27%), visto que os limites são estabelecidos com base em afastamentos de ± 3 desvios-padrões (RIBEIRO; CATEN, 2012), como mostrado a seguir:

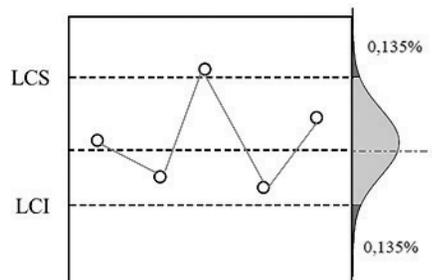


Figura 9.5: Distribuição dos pontos em um gráfico de controle. Com a premissa de uma distribuição normal, há um acúmulo de valores próximos à média, poucos pontos mais afastados e, raramente, pontos fora dos limites de controle.

Fonte: Ribeiro e Caten (2012, p.43).

Mas precisamos ficar atentos, também, a padrões que possam ser percebidos, afinal, se a distribuição for aleatória, não deveria ser percebido qualquer padrão além da própria distribuição normal.

Se os pontos plotados nas cartas apresentam um comportamento não aleatório ou sistemático também são um forte indício de causa especial. Além de verificar pontos fora dos limites, também é importante investigar eventuais padrões não aleatórios na sequência de pontos [...]. A observação de padrões pode disparar uma ação sobre o sistema antes mesmo que um ponto apareça fora dos limites de controle (RIBEIRO; CATEN, 2012, p.44).

Bem, vamos analisar, então, o que vimos no gráfico “estranho” (**Figura 9.3**): o que mais nos chamou a atenção foi o fato de termos um acúmulo de pontos acima da linha central, que representa a média. Como a distribuição dos pontos deveria ser aleatória, obviamente, é possível termos pontos acima ou abaixo da linha central. Na verdade, é razoável dizermos que a probabilidade de um ponto estar acima da linha é de 50% e a probabilidade de estar abaixo é, também, 50% (desde que descartemos a situação de haver ponto com valor exato da média).

Assim, tais probabilidades se assemelham ao ato de jogarmos uma moeda: desconsiderando a rara possibilidade de a moeda cair “em pé”, há 50% de probabilidade de obtermos cara e 50% de probabilidade de obtermos coroa.



Figura 9.6: Ao jogarmos uma moeda, desprezando-se a possibilidade de ela cair em pé, como mostrado aqui, a probabilidade de cair cara ou coroa é igual, isto é, 50% cada. O mesmo acontece com os pontos de um gráfico de controle que esteja submetido somente a causas comuns e no qual, conseqüentemente, haja aleatoriedade.

Fonte: <https://pt.freeimages.com/photo/coin-1416997>.

Mas e a probabilidade de jogarmos a moeda duas vezes e obtermos coroa nas duas vezes? Bem, nesse caso, a probabilidade deixa de ser de 50%, pois temos quatro resultados possíveis e somente um deles é representado por “duas coroas”, como você pode ver a seguir:

Tabela 9.1: Resultados possíveis no “cara ou coroa”

Jogada	Resultados possíveis			
	1	2	3	4
1	Cara	Cara	Coroa	Coroa
2	Cara	Coroa	Coroa	Cara

Desta forma, a probabilidade de obtermos “duas coroas” é de 25% somente. Percebemos, assim, que tais repetições se tornam cada vez menos prováveis. Por exemplo, a probabilidade de três coroas será de 1/8 (ou 12,5%); de quatro coroas, seria 1/16 (6,25%) e assim sucessivamente.

Analogamente, o mesmo acontece com os pontos ao redor da linha central em um gráfico de controle: há uma probabilidade de 50% de um ponto ficar acima (ou abaixo) de tal linha. Já a probabilidade de termos dois pontos seguidos acima ou abaixo é de 25%, etc. Podemos calcular tais probabilidades pela seguinte fórmula:

$$P_n = 0,5^n$$

Sendo

P_n : a probabilidade de n pontos consecutivos do mesmo lado da linha central do gráfico de controle.

n : quantidade de pontos consecutivos.

Vamos verificar algumas dessas probabilidades:

Tabela 9.2: Probabilidades de pontos consecutivos acima ou abaixo da linha central

Pontos consecutivos acima ou abaixo da LC	Probabilidade
2	25,000%
3	12,500%
4	6,250%
5	3,125%
6	1,563%

7	0,781%
8	0,391%
9	0,195%
10	0,098%
11	0,049%
12	0,024%
13	0,012%
14	0,006%
15	0,003%

Volte por um momento ao gráfico da **Figura 9.3** e conte quantos pontos consecutivos há do mesmo lado da linha central (LC)... Contou? São 11, certo? Pois bem, como você pode ver na **Tabela 9.2**, a probabilidade de termos 11 pontos consecutivos do mesmo lado é de aproximadamente 0,05%. Será que podemos considerar, então, o gráfico como sendo referente a um processo sob controle? Óbvio que não! Apesar de todos os pontos estarem dentro dos limites, o processo está claramente sob influência de causas especiais, que precisam ser investigadas.

Também, observando a tabela, identificamos que até oito pontos consecutivos estamos relativamente próximos da probabilidade de termos pontos fora dos limites de controle (0,27%). Assim, podemos estabelecer a *primeira regra* de padrões estatisticamente improváveis dos pontos, que caracterizariam um processo fora de controle (mesmo que dentro dos limites): oito ou mais pontos consecutivos acima ou abaixo da LC.

Importante destacar que diferentes autores apresentam inferências sobre quais limites de probabilidade seriam considerados aceitáveis (VIEIRA; WADA, 1992; MONTGOMERY, 2001; TOLEDO; ALLIPRANDINI, 2004; PEINADO; GRAEML, 2007; YONEYAMA, 2009; GOMES, 2010; RIBEIRO; CATEN, 2012; CHRISTO, 2017; ZVIRTES, 2019) e, conseqüentemente, apresentam regras ligeiramente diferentes entre si. Alguns, por exemplo, consideram como não aceitável a partir de sete pontos consecutivos.

Toledo e Alliprandrini (2004) apresentam ainda uma variação da regra, considerando a possível não continuidade dos pontos acima ou abaixo da LC. De acordo com os autores, seriam também considerados processos fora de controle aqueles em que 10 em 11, 12 em 14, 14 em 17 ou 16 em 20 pontos consecutivos estivessem do mesmo lado da LC.



Ainda que tenha sido usado um gráfico de controle do tipo p como exemplo, a lógica referente aos pontos consecutivos, bem como as demais regras que ainda veremos, se aplica a qualquer tipo de gráfico: $\bar{X}-R$, $\bar{X}-s$, Xi , p , np , c e u .

Bem, vamos agora inspecionar outro gráfico de controle: veja o gráfico a seguir (**Figura 9.7**). Você percebe algo “estranho” nele? Algo que possa ser percebido como não aleatório?

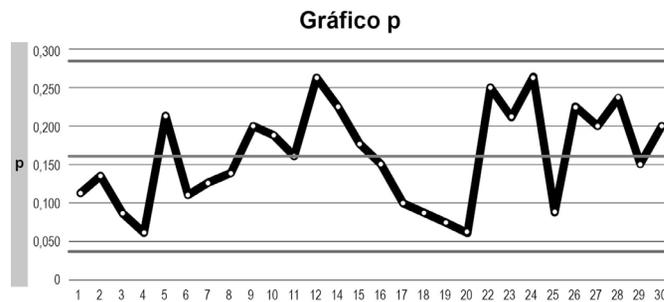


Figura 9.7: Gráfico de controle p (proporção de itens defeituosos). Ainda que todos os pontos estejam dentro dos limites de controle, podemos dizer que o processo monitorado por esse gráfico está sob controle? Avalie-o.

Bem, se você apontou a sequência de pontos descendentes, você está correto! É uma lógica parecida com a da moeda, pois em uma distribuição aleatória, a probabilidade de um ponto ter valor superior ou inferior ao anterior deveria ser de 50% e, desta forma, uma tendência contínua de crescimento ou decréscimo nos valores é altamente improvável.

Para a maioria dos autores, uma sequência crescente ou decrescente de seis ou mais pontos consecutivos seria uma indicação de que o processo está submetido a causas especiais, as quais deveriam ser investigadas, o que seria a nossa *segunda regra* de padrões estatisticamente improváveis dos pontos.



Toledo e Alliprandini (2004) e Gomes (2010) consideram como padrão estatisticamente improvável somente a partir do sétimo ponto.

Vamos analisar mais um gráfico? Veja o gráfico de controle a seguir (Figura 9.8) e tente identificar algo “estranho” nele.



Figura 9.8: Gráfico de controle p (proporção de itens defeituosos). Ainda que todos os pontos estejam dentro dos limites de controle, podemos dizer que o processo monitorado por esse gráfico está sob controle? Preste atenção no gráfico e avalie-o.

Esse é mais difícil, não é? Bem, vamos a uma ajuda e, para isso, usemos, novamente, o exemplo da moeda: imagine jogar a moeda diversas vezes e obter o seguinte resultado:

Tabela 9.3: Resultado possível – mas altamente improvável – no “cara ou coroa”

Jogada	Resultado
1	Cara
2	Coroa
3	Cara
4	Coroa
5	Cara
6	Coroa
7	Cara
8	Coroa
9	Cara
10	Coroa
11	Cara
12	Coroa
13	Cara
14	Coroa
15	Cara
16	Coroa
17	Cara
18	Coroa
19	Cara
20	Coroa

Percebeu algo estranho? Reparou como os resultados estão se alternando? Isso seria probabilisticamente aceitável? Óbvio que não! Então, repare no que está acontecendo no gráfico de controle, a partir da décima medida: não é a mesma coisa? Podemos dizer, então, que o processo está estável? Com certeza não! Tal processo está submetido a causas especiais e requer intervenção, correto?

Essa é, então, a nossa *terceira regra* referente a padrões estatisticamente improváveis: 14 ou mais pontos consecutivos em que se alternam aumentos e quedas nos valores.

Alguns autores propõem, ainda, a subdivisão dos gráficos de controle em áreas, de forma a tornar a análise de padrões mais abrangente. A lógica é a de que, se a distribuição dos valores segue a de uma função

normal, deve haver uma concentração de valores próximos ao valor médio e menos ocorrências conforme nos afastamos desse valor.

Ou seja, como você viu na **Figura 9.4**, aproximadamente 68% dos valores deveriam ficar entre ± 1 desvio-padrão; 27% entre ± 1 e ± 2 desvios-padrões ($95,44\% - 68,26\% = 27,18\%$) e 4% entre ± 2 e ± 3 desvios-padrões ($99,74\% - 95,44\% = 4,30\%$). Assim, traçamos, além dos limites superior e inferior de controle, as faixas referentes a ± 1 e ± 2 desvios-padrões (lembre-se de que os limites superior e inferior representam ± 3 desvios-padrões), como mostrado a seguir.



Figura 9.9: Gráfico de controle p (proporção de itens defeituosos), com identificação das faixas de ± 1 desvio-padrão e ± 2 desvios-padrões. Tal detalhamento permite expandir a análise de padrões estatisticamente improváveis nos gráficos de controle.

A propósito, vamos analisar esse gráfico? O que você acha dele: representa um processo sob controle, ou submetido a causas especiais?

Você pode ter percebido um intenso zigue-zague em um trecho dele, a partir do ponto 19. Mas, pode ter surgido a seguinte dúvida: pela terceira regra não deveríamos considerar como fora de controle se fosse um total de 14 ou mais pontos nessa situação? Além disso, os pontos 26, 27 e 28 não seguem o zigue-zague.

Sim, é verdade. Mas repare em um aspecto mais sutil no gráfico da **Figura 9.9**: os pontos do “quase zigue-zague” estão em regiões que deveriam conter somente 4,3% dos dados, isto é, entre ± 2 e ± 3 desvios-padrões. Lembre-se de que esperamos que mais de $2/3$ dos valores no gráfico se encontrem entre ± 1 desvio-padrão e há um longo trecho em que nenhum ponto está em tal zona. Assim, tal comportamento é altamente improvável e nos leva à *quarta regra*: devemos considerar como um processo fora de controle aquele em que há oito ou mais pontos consecutivos, alternados ou não ao redor da LC, e nenhum deles está dentro da faixa de ± 1 desvio-padrão.

Essa, porém, não é a única regra que pode nos apontar a possível existência de causas especiais: lembrando que a distribuição aleatória que tem aderência a uma distribuição normal prevê proporções de valores como os mostrados na **Figura 9.4**, outras ocorrências podem violar tais aspectos. Repare, por exemplo, no gráfico a seguir:

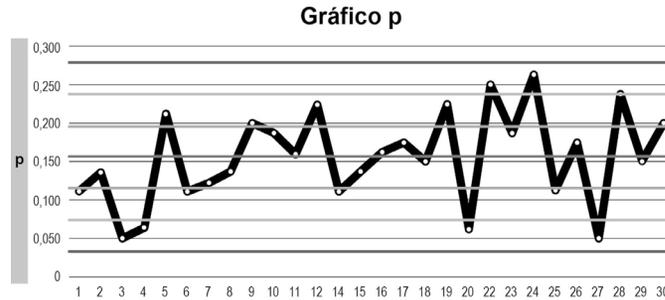


Figura 9.10: Gráfico de controle p (proporção de itens defeituosos), com identificação das faixas de ± 1 desvio-padrão e ± 2 desvios-padrões. Violações ao que seria esperado para uma distribuição normal são indícios da existência de causas especiais e, conseqüentemente, de um processo fora de controle.

Repare que não há nenhum ponto fora dos limites de controle, nem é possível identificar qualquer uma das regras anteriormente listadas. No entanto, um olhar mais atento nos valores nos pontos 2, 3 e 4 nos mostram que temos dois em três pontos consecutivos que estão do mesmo lado da LC e abaixo do limite de -2 desvios-padrões. O mesmo ocorre quando observamos os pontos 22, 23 e 24, com dois dos três pontos além do limite de $+2$ desvios-padrões.

Lembre-se de que a probabilidade de um ponto estar entre as faixas de ± 2 e ± 3 desvios-padrões é de 4,3%. Assim, termos dois em três pontos significa termos 66,67% de ocorrências quando o esperado é de somente 2,15% de probabilidade, visto que estamos analisando somente um dos lados do gráfico. Ou seja, é algo improvável, o que justifica a inclusão de tal regra.

Uma variante desta *quinta regra* seria a de termos quatro de cinco pontos consecutivos fora da faixa de ± 1 desvio-padrão e estando do mesmo lado da LC, como visto no gráfico a seguir:

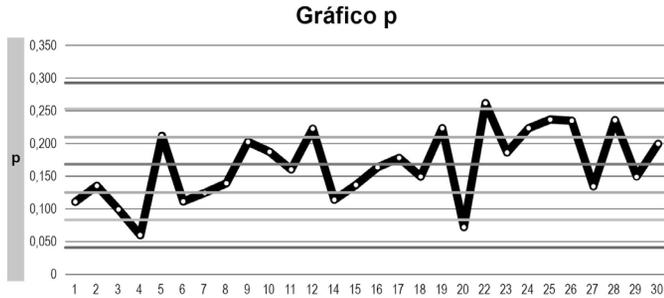


Figura 9.11: Gráfico de controle p (proporção de itens defeituosos), com identificação das faixas de ± 1 desvio-padrão e ± 2 desvios-padrões. Observando os pontos 22, 23, 24, 25 e 26, podemos perceber que quatro deles estão acima da faixa de $+1$ desvio-padrão, caracterizando uma distribuição não aleatória.

Nesse caso, a lógica é semelhante aos dois em três pontos: quatro em cinco pontos representa 80% das ocorrências, onde seriam esperados somente 15,74% (ou seja, a metade de 99,74% menos 68,26%).

Ainda tratando de padrões estatisticamente improváveis, não podemos esquecer, também, que notícias que “boas demais” podem indicar algum problema. Por exemplo, o que você acha do gráfico de controle mostrado a seguir?



Figura 9.12: Gráfico de controle p (proporção de itens defeituosos), com identificação das faixas de ± 1 desvio-padrão e ± 2 desvios-padrões. Não há pontos fora dos limites do gráfico. Na verdade, não há sequer pontos além dos limites de ± 2 desvios-padrões. Um gráfico excelente, mostrando um processo sob estrito controle?

Bem, se a distribuição normal nos indica que temos 68,26% dos valores dentro da faixa de ± 1 desvio-padrão, isso significa que a expectativa é, obviamente, termos 31,74% dos valores fora de tal faixa, não é mesmo? Assim, termos uma excessiva concentração de valores dentro da faixa de ± 1 desvio-padrão, ao contrário de nos mostrar um processo sob controle,

mostra que há algo estranho, isto é, provavelmente causas especiais estão agindo sobre o referido processo.

Isso define a nossa *sexta regra*: devemos considerar um processo fora de controle quando ele apresenta 15 ou mais pontos consecutivos dentro da faixa de ± 1 desvio-padrão. Ribeiro e Caten (2012) nos apresentam, ainda, o que poderíamos considerar como regras adicionais, conforme mostrado nas figuras a seguir, que dependem menos de uma quantificação de pontos em determinada situação, mas que usualmente são facilmente observáveis.

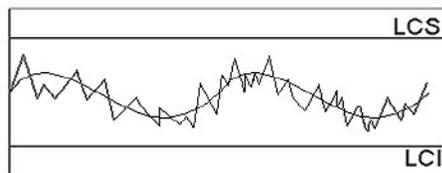


Figura 9.13: Comportamento cíclico. Se a premissa é a de que as variações são aleatórias, devido tão-somente a causas normais, o aparecimento de um padrão cíclico ou sazonal viola tal aspecto, mesmo que não haja pontos fora dos limites ou que não tenha sido violada qualquer outra das regras estudadas, e só poderia ser causado por uma causa especial, a qual precisa ser investigada.

Fonte: RIBEIRO; CATEN, 2012 (p. 45).

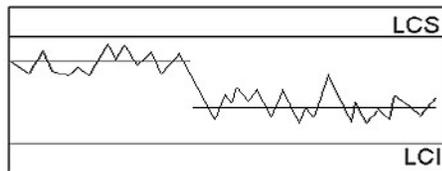


Figura 9.14: Mudança de média. Também denominada shift (do inglês “mudar” ou “mudança”), a mudança do valor médio só ocorre mediante a influência de causas especiais, visto que o valor médio é determinado justamente pelos dados levantados sobre o próprio processo. Assim, os resultados do processo só mudam se o próprio processo mudar.

Fonte: RIBEIRO; CATEN, 2012 (p. 45).

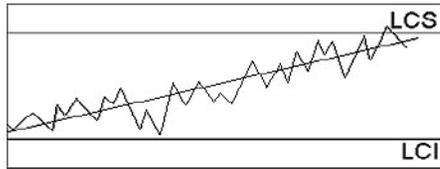


Figura 9.15: Tendência linear. Mesmo que o crescimento ou decréscimo dos valores não seja como estipulado na segunda regra de padrões estatisticamente improváveis, isto é, de uma sequência crescente ou decrescente de seis ou mais pontos consecutivos, a percepção de tal tendência é suficiente para caracterizar um processo fora de controle. Isso se explica pelo fato de que a tendência é usualmente mais visível do que a própria oscilação nos valores, o que faz sentido se imaginarmos que a tendência é ocasionada por causas especiais, enquanto as oscilações se devem a causas normais.

Fonte: RIBEIRO; CATEN, 2012 (p. 45).

As situações mostradas, bem como as regras descritas e exemplificadas, servem para expandir a capacidade de análise dos gráficos de controle além da mera observação dos limites superior e inferior de controle, tornando tal ferramenta ainda mais útil para a manutenção e melhoria da qualidade para as organizações. Uma dúvida que pode eventualmente surgir é qual dos tipos de gráfico de controle utilizar para determinada situação. É isso que você estudará a seguir.

Escolha entre gráficos de controle de atributos e variáveis

A escolha entre os tipos de gráficos de controle é, provavelmente, de acordo com Christo (2017), uma das dúvidas mais constantes na fase de aprendizagem das cartas de controle. De acordo com a autora, as diferenças básicas entre as cartas por variáveis e por atributos seriam:

- Uma vantagem das cartas por atributos é permitir o controle de mais de um característica de qualidade em uma única carta, pois a medição consiste em identificar se o item está conforme ou não conforme em relação às especificações de determinados características de qualidade.
- Por outro lado, uma carta por variável exige geralmente uma medição mais complexa. Basicamente, para cada característica selecionada, é

necessário um conjunto de cartas de controle (na realidade são duas cartas: uma para controle da média e outra para controle da dispersão do processo).

- Logo, sob o ponto de vista prático, as cartas por atributos são mais fáceis de serem manuseadas e apresentam, em geral, um menor custo de medição.
- Entretanto, deve-se considerar, ainda sob o ponto de vista do custo de amostragem, que as cartas por variáveis exigem um menor tamanho de subgrupo, fato esse que pode ser vantajoso dependendo do característico de qualidade (um exemplo são os processos que exigem medições destrutivas).
- As cartas por variáveis apresentam muito mais informações (por exemplo, sobre a média, a variabilidade e a capacidade do processo) do que as por atributos, facilitando a identificação do motivo das causas especiais que ocorrem no processo.
- Entretanto, a principal vantagem das cartas por variáveis sobre as cartas por atributos é relacionada ao controle do processo em si.
- As cartas por variáveis permitem que ações *preventivas* sejam executadas antes que muitas peças defeituosas sejam produzidas. Já as por atributos permitem que ações *corretivas* sejam executadas após ter sido produzida uma relativa quantidade de itens defeituosos (CHRISTO, 2017, p. 12-13, grifos no original).

A seguir são apresentadas algumas dicas para a escolha da carta de controle mais adequada a um processo.

Carta X-R

Das cartas de controle por variáveis essa é a mais frequentemente aplicada na indústria. Esse tipo de carta de controle é adequado quando são utilizados subgrupos que possuem entre duas e nove amostras e o tamanho do subgrupo situa-se em torno de quatro ou cinco amostras.

Na prática, o tamanho da amostra deve ser determinado com base na capacidade de detecção de mudanças. Porém, à medida que o tamanho do subgrupo aumenta, diminui a sensibilidade da amplitude R como estimador do desvio-padrão do processo. Para subgrupos com tamanho próximo de 10, a amplitude perde significativamente sua sensibilidade como estimador.

Carta X-Am

Esse tipo de carta de controle é utilizado quando o tamanho do subgrupo de amostra é igual a um, sendo necessário calcular a amplitude entre os subgrupos (amplitude móvel).

Alguns exemplos de aplicação desta carta são:

- processos homogêneos em que não faz sentido subgrupos de amostras com tamanho maior que uma unidade. Exemplo: o controle de temperatura de um banho químico;
- quando se tem inspeção 100% automatizada;
- para processos cuja taxa de produção é baixa, não faz sentido acumular resultados ao longo do tempo para a avaliação da estabilidade do processo;
- quando o tamanho de amostra maior que uma unidade for economicamente inviável.

Carta X-S

Esta é uma opção para a carta X-R, quando o tamanho das amostras é maior ou igual a 10. Porém, muitas vezes, amostras desse tamanho são inviáveis economicamente.

Assim como para a carta X-R, o tamanho da amostra deve ser calculado com base na capacidade de detecção de mudanças no processo.

Carta *p*

A carta de controle “*p*” é utilizada quando a característica de qualidade de interesse é representada pela proporção de itens defeituosos produzidos.

Alguns exemplos são:

- percentual de componentes elétricos defeituosos produzidos em uma hora de produção;
- percentual de pistões com diâmetro fora do especificado produzidos em um turno de trabalho.

Carta c

A carta “c” é utilizada quando se deseja controlar o número total de defeitos em uma unidade do produto.

Alguns exemplos são:

- número de quebras de uma ferramenta durante um mês de trabalho de uma indústria;
- número de riscos em uma chapa metálica;
- número de soldas defeituosas em um aparelho de rádio;
- número de defeitos em 100 metros de uma tubulação.

Carta u

A carta “u” tem a mesma aplicação da carta “c”. A única diferença é que o tamanho do subgrupo para a carta “u” é maior do que um.

Assim, um exemplo seria o controle do número de riscos em duas chapas metálicas. Logo, para esse caso, o tamanho do subgrupo é de duas amostras.

Carta np

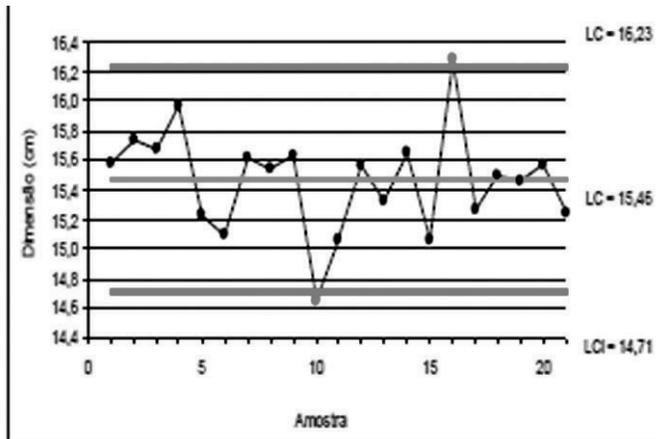
A carta “np” aplica-se aos mesmos casos da carta “p”. Entretanto, essa carta é utilizada quando se deseja saber o número de itens não conformes em vez de conhecer a proporção de itens defeituosos.

===== **Atividade 1** =====

Atende aos objetivos 1 e 2

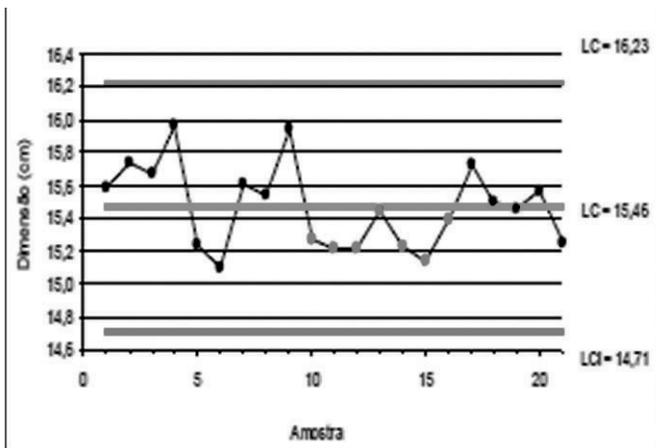
No conteúdo desta aula, você aprendeu como analisar gráficos de controle. Analise os exemplos a seguir e verifique se os gráficos representam processos estáveis, justificando a sua resposta.

a)



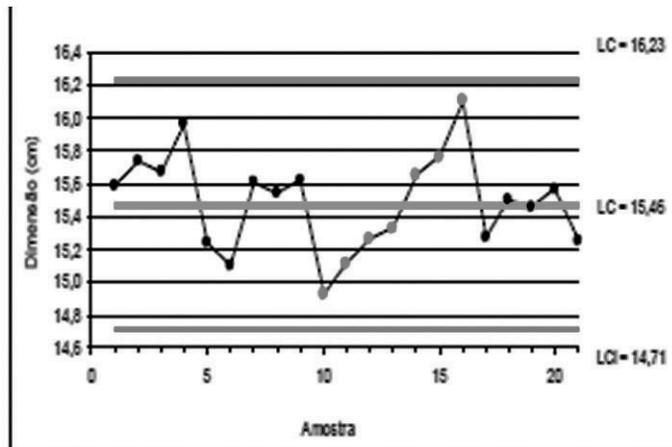
Fonte: Ribeiro e Caten (2012, p. 45).

b)



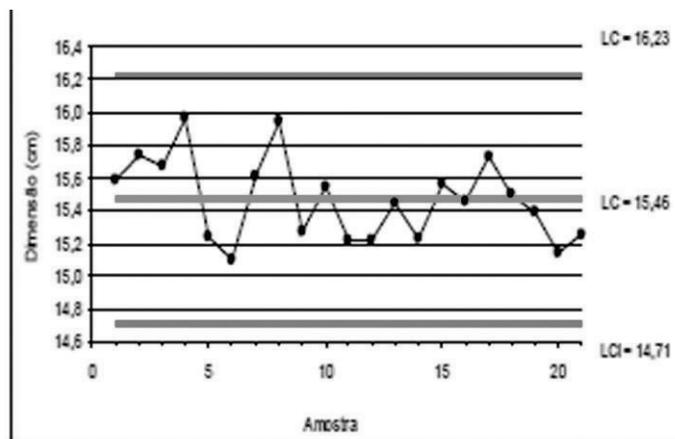
Fonte: Ribeiro e Caten (2012, p. 45).

c)



Fonte: Ribeiro e Caten (2012, p. 45).

d)



Fonte: Ribeiro e Caten (2012, p. 45).

Resposta comentada

a) O gráfico apresenta pontos acima e abaixo dos limites de controle, caracterizando, portanto a ocorrência de causas especiais, não estando sob controle.

b) O gráfico apresenta sete pontos consecutivos abaixo da LC. Para alguns autores, já seria suficiente para caracterizar como fora de controle, enquanto outros autores só consideram tal situação a partir do oitavo

ponto. De qualquer forma, é uma situação limítrofe e seria apropriado que se iniciasse uma investigação.

c) O gráfico apresenta sete pontos consecutivos ascendentes, o que viola a regra referente a padrões estatisticamente improváveis, sendo considerado, portanto, fora de controle.

d) O gráfico não aparenta violar qualquer regra de estabilidade, inferindo-se, portanto, que o processo está sob controle.

Conclusão

A análise dos padrões de distribuição dos valores em um gráfico de controle complementa a análise que é feita considerando os limites aceitáveis (limites superior e inferior de controle), tornando-se uma aliada nas ações de manutenção e melhoria do controle de qualidade nas empresas.

As regras para avaliação, de fácil uso e aplicação, podem ser aplicadas tanto a gráficos de controle por variáveis como atributos. A partir da constatação da não estabilidade dos processos, seja pela ocorrência de pontos fora dos limites de controle ou por qualquer padrão que indique a não aleatoriedade dos dados, infere-se a possibilidade de efeitos de causas especiais, demandando a intervenção no processo e a investigação das causas-raiz, de forma a evitar que danos maiores possam ocorrer.

Vale destacar a importância de utilizar ferramentas complementares em tal processo, como diagrama de causa e efeito, diagrama de Pareto, histogramas, etc.

Resumo

Para a análise dos gráficos de controle, além da verificação de haver ou não valores fora dos limites de controle, são utilizadas regras adicionais, as quais indicariam a ocorrência de causas especiais, mesmo que os limites superior ou inferior não tenham sido ultrapassados. São elas:

1. oito ou mais pontos consecutivos acima ou abaixo da linha central (LC) (obs: para alguns autores, sete pontos já caracterizariam tal situação);

2. sequência crescente ou decrescente de seis ou mais pontos consecutivos;
3. 14 ou mais pontos consecutivos em que se alternam aumentos e quedas nos valores;
4. oito ou mais pontos consecutivos, alternados ou não ao redor da LC, e nenhum deles está dentro da faixa de ± 1 desvio-padrão;
5. dois de três pontos consecutivos além do limite de ± 2 desvios-padrões e/ou quatro de cinco pontos consecutivos fora da faixa de ± 1 desvio-padrão, estando do mesmo lado da LC;
6. 15 ou mais pontos consecutivos dentro da faixa de ± 1 desvio-padrão;
7. comportamento cíclico;
8. mudança de média (*shift*) e
9. tendência linear.

Os gráficos de controle podem ser aplicados a variáveis contínuas (ex: medidas de diâmetro, peso, etc.), na forma dos gráficos \bar{X} -s e \bar{X} -R. Há ainda o gráfico X_i : uma variante do Gráfico \bar{X} -R, utilizado quando há taxa de produção muito baixa. Por isso, também é chamado de gráfico de controle para valores individuais.

Os gráficos por atributos monitoram as condições de peças ou produtos, no sentido de conterem alguma forma de não conformidade (defeitos). A seleção do tipo de gráfico por atributo (c, u, p ou np) leva em consideração se analisaremos a quantidade de defeitos ou de peças defeituosas, bem como o tamanho das amostras coletadas.

Leituras recomendadas

SPOHR, Caroline. *Os gráficos de controle como ferramenta de análise do desperdício alimentar em um restaurante universitário*, 2014. 82f. Monografia (Especialização em Estatística e Modelagem Quantitativa). Santa Maria: Universidade Federal de Santa Maria, 2014. Disponível em: https://repositorio.ufsm.br/bitstream/handle/1/987/Spohr_Caroline.pdf?sequence=1. Acesso em: 06 mar. 2019.

Informação sobre o próximo conteúdo

Na próxima aula, continuaremos os estudos dos gráficos de controle, com foco na análise da estabilidade e capacidade dos processos.

Referências bibliográficas

CHRISTO, E. S. *Aula 9 – Ferramentas para o controle da qualidade – Parte VII*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 9), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=12>. Acesso em: 02 jul. 2019.

GOMES, F. M. *C.E.P. Lorena*: Colégio Patrocínio de São José, 2010.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. 4. ed. Nova York: John Wiley & Sons, 2001.

PEINADO, J.; GRAEML, A. R. *Administração da produção: operações industriais e de serviços*. Curitiba: UnicenP, 2007.

RIBEIRO, José Luis Duarte; CATEN, Carla Schwengber ten. *Controle estatístico do processo: cartas de controle para variáveis, cartas de controle para atributos, função de perda quadrática, análise de sistemas de medição*. Série monográfica Qualidade. Porto Alegre: FEENG/UFRGS – Fundação Empresa Escola de Engenharia da UFRGS - Universidade Federal do Rio Grande do Sul, 2012.

SONDAGENS E ESTUDOS DE OPINIÃO. *Estatística descritiva*. Coimbra: Escola Superior de Educação do Politécnico de Coimbra, 25 nov. 2012. Disponível em: <https://sondagenseestudosdeopinio.wordpress.com/estatistica/estatistica-descritiva/>. Acesso em: 3 jan. 2019.

TOLEDO, J. C.; ALLIPRANDINI, D. H. *Controle estatístico da qualidade*. São Carlos: Universidade Federal de São Carlos, 2004.

VIEIRA, S.; WADA, R. *As 7 ferramentas estatísticas para o controle da qualidade*. 7. ed. Brasília: QA & T, 1992.

YONEYAMA, T. *Controle estatístico de processo*. São José dos Campos: Instituto Tecnológico da Aeronáutica, 2009.

ZVIRTES, Leandro. *Métodos e filosofia do controle estatístico de processos*. Joinville: UDESC/CCT – Engenharia de Produção e Sistemas, 2019. Disponível em: http://www.joinville.udesc.br/portal/professores/alan/materiais/A6___Cartas_de_controle.pdf. Acesso em: 1º mar. 2019.

Aula 10

Análise da estabilidade e
capacidade do processo

Meta

Verificar se o processo está estável, ou não, e se é capaz de se estabilizar com o auxílio do gráfico de controle e da distribuição normal.

Objetivos

Esperamos que, ao final deste aula, você seja capaz de:

1. saber como avaliar se o processo está estável ou não;
2. analisar, por meio do gráfico de controle e da distribuição dos dados, a capacidade de o processo de se tornar estável.

Pré-requisitos

Funções estatísticas e distribuição normal, causas comuns e causas especiais, gráficos \bar{X} -R, \bar{X} -s, p , np , c e u , conteúdos abordados nas aulas anteriores.

Introdução

A utilização dos gráficos de controle permite apurar se os processos estão estáveis, isto é, se estão sujeitos tão-somente a causas comuns, ou se estão sofrendo efeitos de causas especiais, o que faz com que tenham variações fora do que é estatisticamente previsível ou aceitável. Mas tais gráficos se baseiam no próprio desempenho do processo para fazer tal análise, sem incorporar qualquer tipo de análise quanto aos resultados do processo: mesmo estáveis, atendem às especificações de projeto do produto ou de seus componentes.

Desta forma, uma vez que nos certifiquemos de que os processos são capazes de garantir a estabilidade do que está sendo produzido, é preciso verificar se geram produtos que estão em conformidade com as especificações. Isso é feito desta forma, primeiramente pela análise de estabilidade e, em seguida, pelo uso dos índices de capacidade do processo.

É isso que você estudará aqui: você continuará estudando o gráfico de controle, mas, agora, com foco no seu uso para avaliar a capacidade do processo produtivo. Bons estudos!

A utilização dos gráficos de controle trouxe grandes avanços em termos de qualidade e produtividade para as empresas. Não somente passou a ser possível conciliarmos altos volumes de produção com a possibilidade de não termos de fazer inspeções 100%, mas, principalmente, passou a ser possível nos anteciparmos aos problemas, isto é, detectarmos mudanças no processo que poderiam gerar variações indesejadas e não conformidades antes mesmo que elas acontecessem (vide a Aula 1).

A lógica do controle estatístico de processos se baseia no fato de que, se o que foi produzido é adequado e se nada mudar no processo, o que se continua a produzir também deve ser adequado, ao passo que, se mudanças são detectadas, não podemos mais garantir tal situação (vide a Aula 6). Ou seja, se o processo permanece o mesmo, é esperado que o que estamos produzindo permaneça como é; enquanto, se mudamos o processo, produziremos algo “diferente” (que pode ser adequado ou não) e que, conseqüentemente, precisa ser avaliado e investigado.

Desta forma, ainda que o que é produzido possa ter pequenas diferenças, que são inerentes ao processo produtivo (as chamadas causas comuns, sobre as quais você aprendeu nas Aulas 2 e 6), elas ocorrem dentro de faixas “aceitáveis”, que são definidas por meio de

métodos estatísticos: são os limites de controle, superior e inferior, que você aprendeu na Aula 6. Valores que estão além de tais limites – isto é, acima do limite superior ou abaixo do limite inferior – seriam valores “fora do esperado estatisticamente”, indicando a possibilidade de ocorrência de causas especiais.

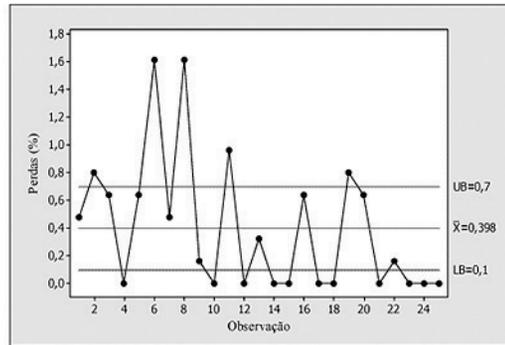
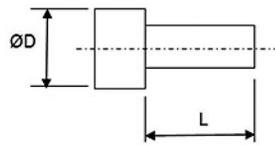


Figura 10.1: Gráfico de controle por variáveis. A posição dos pontos representa os valores analisados do processo e a existência de pontos acima do limite superior ou abaixo do limite inferior (linhas UB e LB no gráfico mostrado) seriam indícios de que o processo está submetido a causas especiais, não estando, portanto, sob controle. Tal ocorrência seria um sinal de alerta e um processo de investigação deveria ser iniciado, para que se identificasse o que havia ocorrido no processo, isto é, o que “mudou” nele e se tal mudança traz alguma implicação.

Fonte: Adaptado de Silva et al. (2008, p. 299)

Mas você reparou que a lógica dos gráficos de controle se baseia somente no histórico dos dados do próprio processo? Reparou, também, que não há, de fato, uma comparação com as especificações e medidas de projeto das peças que são produzidas? Ou seja, um processo sob controle é, a princípio, aquele em que a medida analisada varia somente dentro dos limites que foram estabelecidos por medidas anteriores do mesmo processo. Não sabemos, porém, se as medidas estão dentro dos limites estabelecidos pelos projetistas. Por exemplo, vamos rever uma peça que estudamos na Aula 6 (originalmente, **Figura 6.11**):



ØD (mm)	L (mm)
10,00 ±0,10	20,00 ±0,25

Figura 10.2: Peça-exemplo.

Observe que as medidas $10,00 \pm 0,10$ e $20,00 \pm 0,25$ não são utilizadas para absolutamente qualquer cálculo nas cartas de controle, isto é, para definir os limites do gráfico: como você viu nas Aulas 6 e 7, o cálculo dos limites tomaria por base as médias das amostras somente. Ou seja, hipoteticamente, poderíamos ter um processo sob controle, mas produzindo peças não conformes.

É necessário, então, apurar não somente se o processo produtivo está submetido somente a causas comuns, mas, também, verificar se este é capaz de produzir peças que estão de acordo com as especificações do projeto. Ou, como citam Costa, Epprecht e Carpinetti (2016, p. 116), “Até aqui, ocupamo-nos do ajuste e da estabilidade do processo, que estão associados à presença ou ausência de causas especiais. Agora estudaremos a capacidade do processo, isto é, sua capacidade de produzir itens conformes, ou seja, de acordo com as especificações de projeto”. Vamos, então, explorar e compreender como tais análises são feitas, de forma a garantir a qualidade dos produtos que são produzidos.

Processos sob controle

Vamos recordar alguns aspectos já estudados sobre os gráficos de controle: quando os processos estão sob controle, a variação nos valores ocorre de forma randômica, respeitando os padrões referentes a uma distribuição normal (vide a Aula 6). Desta forma, um processo que não esteja submetido a causas especiais deverá apresentar valores que ficarão dentro dos limites de controle calculados para as cartas de controle.

Mas “estar dentro dos limites” não é a única característica de um processo sob controle: a aderência dos dados a uma distribuição normal também tem de ser verificada. Para tanto, a construção de histogramas,

a plotagem dos dados em uma folha de distribuição normal, o teste gráfico de valores teóricos de Z (RIBEIRO; CATEN, 2012) e outros testes estatísticos podem ser utilizados (vide a Aula 7). E, ainda, a distribuição normal prevê uma concentração de valores próximos ao valor médio, os quais se tornam mais raros quanto mais estiverem afastados deste valor médio (que é a característica mais conhecida desse tipo de distribuição, junto à simetria da curva).

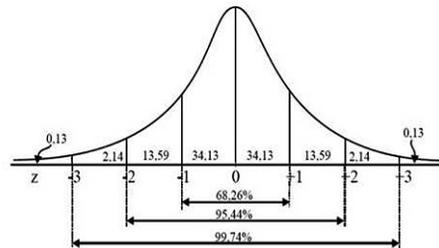


Figura 10.3: Curva normal. A representação de uma distribuição normal mostra uma concentração de valores ao redor do valor central (média): 68,26% das ocorrências dentro de uma faixa de ± 1 desvio-padrão; 95,44% na faixa de ± 2 desvios-padrões; e 99,74% na faixa de ± 3 desvios-padrões.

Fonte: sondagens e estudos de opinião (2012).

Assim, padrões de comportamento não aleatórios dos dados indicariam que o processo está fora de controle. Tais padrões, como você estudou na Aula 9 são:

1. oito ou mais pontos consecutivos acima ou abaixo de LC (obs.: para alguns autores, sete pontos já caracterizariam tal situação);
2. sequênciacrescenteoudecrescentedeseisoumais pontos consecutivos;
3. 14 ou mais pontos consecutivos em que se alternam aumentos e quedas nos valores;
4. oito ou mais pontos consecutivos, alternados ou não ao redor da LC, e nenhum deles está dentro da faixa de ± 1 desvio-padrão;
5. dois de três pontos consecutivos além do limite de ± 2 desvios-padrões e/ou quatro de cinco pontos consecutivos fora da faixa de ± 1 desvio-padrão, estando do mesmo lado da LC;
6. 15 ou mais pontos consecutivos dentro da faixa de ± 1 desvio-padrão;

7. comportamento cíclico;
8. mudança de média (*shift*) e
9. tendência linear.

Assim sendo, um processo só pode ser considerado estável, isto é, submetido tão-somente a causas comuns, se seu gráfico de controle não apresentar pontos fora dos limites de controle, se os pontos estiverem normalmente distribuídos e se não apresentarem padrões de comportamento estatisticamente improváveis.

Somente os processos que se enquadrarem em tais características poderão ser avaliados quanto à sua capacidade de garantir medidas de acordo com as especificações técnicas nas peças que estão sendo produzidas. A justificativa para que somente processos estáveis possam servir de base para calcular sua capacidade de garantir as medidas de especificação é que os processos não estáveis não seriam “confiáveis”, ou seja, seriam imprevisíveis, por estarem submetidos a causas especiais e, conseqüentemente, não poderíamos contar com eles para manter resultados alcançados e, portanto, medidas. Como destaca Christo (2017, p. 4), “A verdadeira capacidade do processo só deve ser determinada após o mesmo ter sido otimizado e estabilizado”.

Análise da capacidade do processo

Não havendo indícios de causas especiais, com o processo estável, seguindo uma distribuição normal e sem apresentar padrões de comportamento estatisticamente improváveis, é possível mensurar a capacidade do processo, a fim de verificar se seu desempenho é aceitável ou não com relação às especificações do produto que é produzido (BONIFÁCIO; VASCONCELLOS, [2004?]).

A palavra “capacidade” pode transmitir uma falsa ideia sobre o que de fato analisamos nos processos em termos de controle da qualidade: é comum que a interpretação seja sobre a capacidade de produzir muito, ou seja, alta capacidade de produção (capacidade, em termos de máquinas, equipamentos e recursos em geral para produzir em altos volumes). Mas, sob a ótica do controle estatístico da qualidade, o sentido correto é o da palavra *capability* (em inglês), cujo significado é distinto, como vocês viram na Aula 6: é a facilidade ou potencialidade para um uso indicado

ou desenvolvimento e desdobramento (ROCHA, 2005), aplicando-se, portanto, à facilidade ou potencialidade do processo para produzir peças conforme as especificações estabelecidas.



É comum ser utilizada a expressão “capabilidade do processo”, ao invés de “capacidade do processo”, de forma a evitar erros de interpretação. Ainda que “capacidade” seja a forma tradicional, usualmente utiliza-se “capabilidade” no ambiente industrial.

Vamos tomar como exemplo a peça que vimos anteriormente (**Figura 10.2**):

Podemos imaginar que tal peça é montada em um conjunto em que o diâmetro D deve encaixar em um rebaixo de outra peça: se o diâmetro for muito grande, a montagem não será possível, devido à interferência entre a peça e o rebaixo. Mas, se o diâmetro for muito pequeno, a montagem ficará “frouxa” e existirá uma folga muito grande, o que causaria vibração durante o uso.

Por isso, o diâmetro deve estar dentro de uma estreita faixa de medidas: não menos de 9,90 mm – limite inferior de especificação (LIE) – e não mais de 10,10 mm – limite superior de especificação (LSE) –, para o bom funcionamento do conjunto. Essa é a especificação do projeto. Mas o que o processo produtivo está gerando? Não há como saber: precisamos produzir determinada quantidade e medir a amostra, de tal forma que possamos calcular a média da medida e sua dispersão (ou seja, o desvio-padrão da medida).

Digamos que, por exemplo, a amostra nos indique que o processo está gerando peças cuja medida média do diâmetro seja de 9,96 mm e que o desvio-padrão é de 0,02 mm. Nesse caso, considerando afastamentos de ± 3 desvios-padrões, teríamos peças cuja dimensão estaria entre 9,90 mm e 10,02 mm. Tais valores são denominados limites naturais, ou seja, limite natural inferior (LNI) e limite natural superior (LNS).



ATENÇÃO: não podemos confundir as medidas obtidas no processo, considerando as faixas de ± 3 desvios-padrões, com os limites nos gráficos de controle. Como você aprendeu na Aula 6, o desvio-padrão para se converter em erro padrão é dividido pelo \sqrt{n} , onde n é o tamanho da amostra, como mostrado na equação a seguir:

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Desta forma, como citam Costa, Epprecht e Carpinetti (2016):

a escala da variação entre as médias amostrais [...] é menor que a dos valores individuais [...]. A razão entre as escalas nem é fixa, pois depende de n [...] nem mesmo a razão da distância entre os limites de especificação e a distância entre os limites de controle é fixa, pois a última depende do tamanho da amostra n (p. 117-118).

Bem, vamos ver, então, o que temos com os afastamentos de 9,90 mm e 10,02 mm para uma especificação de 9,90 mm a 10,10 mm (observe que os limites naturais são representados como as extremidades da curva normal, enquanto os limites das especificações são representados como barras verticais na figura):

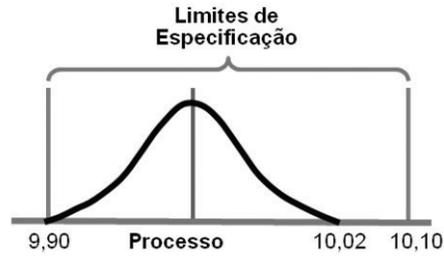


Figura 10.4: Limites de especificação e limites do processo. No exemplo analisado, a menor medida aceita (especificação de projeto) é de 9,90 mm, o que coincide com o limite de -3 desvios-padrões do processo, ao passo que o limite de $+3$ desvios-padrões do processo (10,02 mm) está afastado do limite máximo de especificação, que é de 10,10 mm. Ou seja, há certa “folga” no limite superior, enquanto há coincidência de valores no limite inferior.

Como explicamos isso? E quais são as consequências? Bem, primeiramente, é fácil perceber que o processo não está “centrado”: enquanto o valor médio da especificação é de 10 mm, o valor médio do que está sendo produzido é de 9,96 mm. Ou seja, há “deslocamento” de 0,04 mm (o que não significa que necessariamente isso seja um problema).

Por outro lado, você pode perceber uma “sobra” entre a variação do processo e a faixa de medidas aceitáveis de acordo com a especificação: enquanto a faixa de tolerância da especificação é de 0,20 mm (repare que a especificação da tolerância indica $\pm 0,10$ mm, totalizando, portanto 0,20 mm), o processo varia (considerando ± 3 desvios-padrões) somente 0,12 mm (visto que o desvio padrão é de 0,02 mm). Ou seja, a variação do processo “ocupa” somente 60% da especificação, o que é bom: há “folga” na variação.

No entanto, tal folga acaba tendo seu efeito reduzido pelo fato de o processo não estar centrado: a folga só se aplica a “um dos lados” (entre 10,02 mm e 10,10 mm), enquanto na outra extremidade (9,90 mm) não há qualquer folga. Vamos utilizar tal exemplo para fazer algumas reflexões: já que a especificação do produto para bom funcionamento é que o diâmetro seja de, no mínimo 9,90 mm e no máximo 10,10 mm, o que você acha de o processo produtivo gerar, entre ± 3 desvios-padrões, os valores entre 9,90 mm e 10,02 mm? Pense um pouco sobre isso...

O extremo superior não parece ser preocupante, pois, como vimos, há uma “folga” de 0,08 mm ($10,10 - 10,02 = 0,08$ mm). Mas, no extremo

inferior, a situação não é a mesma: não há folga alguma e, se lembrarmos que os 9,90 mm do processo foram calculados com base em um afastamento de -3 desvios-padrões da média, chegaremos à conclusão, com base na distribuição da curva normal, que há uma probabilidade de 0,13% de peças não conformes. Pode parecer muito pouco, mas, com um grande volume de produção, isso representa mais de uma peça ou produto defeituoso a cada mil produzidos.



Figura 10.5: Produto defeituoso. Produtos defeituosos podem causar sérios impactos para as empresas que os fabricam e comercializam: além do desconforto que o mau funcionamento possa causar, eventualmente há riscos de danos às instalações, ao meio ambiente e à própria segurança das pessoas, podendo causar danos irreparáveis à imagem das empresas.

Fonte: <https://pixabay.com/vectors/device-error-device-defect-154484/>.

Por outro lado, você deve ter analisado, também, que se o processo fosse centrado, a situação seria bem melhor: a folga estaria “distribuída” e teríamos menor probabilidade de itens defeituosos. Na verdade, poderíamos calcular a probabilidade por meio da distribuição na curva normal: a partir do valor médio 10,00 mm e mantendo os afastamentos de ± 3 desvios-padrões, o processo nos propiciaria ficarmos entre 9,94 mm e 10,06 mm, contra uma faixa de especificação de 9,90 mm a 10,10 mm.

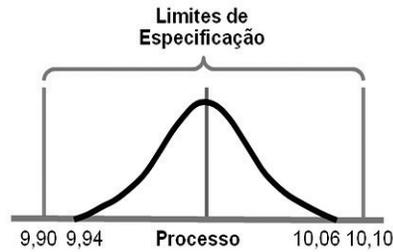


Figura 10.6: Limites de especificação e limites do processo. Agora, com o processo centrado, há folga em ambos os lados. A princípio, pode não parecer ser tão vantajoso, visto que a folga total permanece a mesma, mas o fato é que assim afastamos os limites naturais dos limites das especificações que estão mais próximas, que são grande fator de preocupação.

Observe que as variações do processo só ficariam além dos limites das especificações se houvesse um afastamento de mais de 5 desvios-padrões, visto que o afastamento unilateral é 0,10 mm e o desvio-padrão, 0,02 mm ($0,10/0,02 = 5$). Utilizando a função `DIST.NORMP` do Excel para tal afastamento, chegamos à conclusão de que a probabilidade de termos uma ocorrência abaixo ou acima das especificações é de 0,00003%, o que representaria somente um item defeituoso a cada mais de 3.000.000 produzidos. Bem, melhor, não é mesmo?

No entanto, a centralização não é o único aspecto a ser avaliado: a dispersão nos valores é o fator de maior preocupação. Observe, por exemplo, a imagem a seguir: o que você percebe de preocupante com o processo (que, por sinal, está perfeitamente centralizado)?

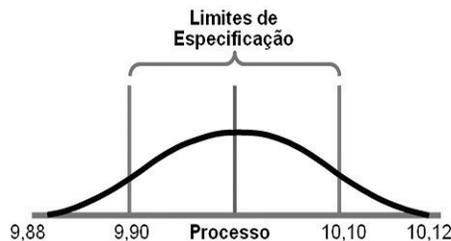


Figura 10.7: Limites de especificação e limites do processo. Repare que os limites naturais do processo estão além dos limites de especificação. Isso significa que a probabilidade de serem produzidos itens não conformes é bastante grande.

Repare que a curva normal está mais “aberta”, isto é, os dados estão mais dispersos. Na verdade, tão dispersos que seus extremos (± 3 desvios-padrões) estão além dos limites de especificações. Como o processo está centrado, é fácil inferir o valor do desvio-padrão nesse exemplo: o afastamento de 0,12 mm (por exemplo, $10,12 - 10,00 = 0,12$) representa os 3 desvios-padrões e, conseqüentemente, o valor de desvio-padrão nesse caso é de 0,04 mm (o dobro do valor do exemplo anterior). E o que isso representa? Bem, se quando os limites naturais coincidem com os limites de especificação, a probabilidade de termos itens não conformes é de 0,13%, quando os limites naturais vão além dos limites de especificação, essa probabilidade é muito maior: utilizando novamente a DIST. NORMP do Excel para o afastamento de 2,5 desvios-padrões ($0,10/0,04 = 2,5$), encontramos tal probabilidade como sendo de 0,62%, o que representa cerca de um item defeituoso a cada 160.

Observe que um processo não centralizado é, de forma geral, mais fácil de lidar e serem geradas ações de melhoria do que um processo que gera resultados muito dispersos. Vamos compreender a razão de tal afirmação: observe os dois alvos a seguir. As marcas neles representam tiros com pistola a ar que estavam apoiadas na hora do tiro. Nenhum dos dois mostra que o centro do alvo foi acertado, não é mesmo?

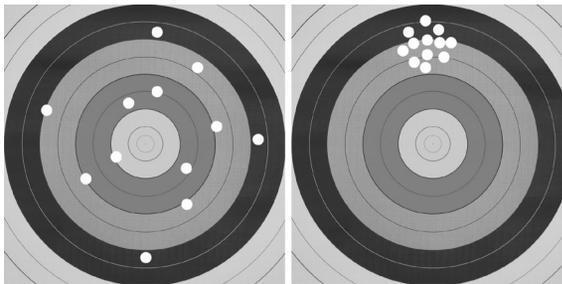


Figura 10.8: Dispersão e centralização. Repare como as marcas de tiro no alvo da esquerda estão “espalhadas”, dispersas. Ou seja, qualquer resultado (posição dos tiros) pode ocorrer quando utilizada tal pistola. Há muita incerteza. Por outro lado, o que você vê no alvo da direita é uma grande previsibilidade nos resultados.

Fonte: Adaptado de <https://pt.freeimages.com/photo/target-1166687>.

Se você quisesse escolher qual pistola de ar usar para atingir o centro do alvo, qual escolheria? Pense um pouco sobre isso... Repare que a pistola utilizada no alvo da esquerda gerou marcas de disparos totalmente

“espalhadas”, dispersas. Ou seja, apesar de parecer que os disparos foram centrados, pois estão ao redor do centro do alvo, não há precisão nos tiros, isto é, não sabemos, de fato, que resultado esperar dos tiros. Já no alvo da direita, observe como todos os tiros estão próximos. Podemos inferir que os tiros da direita variam por conta de causas comuns, enquanto os da esquerda estão submetidos a causas especiais (vide Aula 2).

Mas o mais importante é que, para acertarmos o centro do alvo com a pistola da direita, basta ajustar a altura do apoio dela (observe que todos os tiros estão concentrados acima do centro do alvo), ao passo que, no alvo da esquerda, seria tudo muito mais complicado, pois os tiros são erráticos e pouco poderíamos fazer para melhorar o resultado se mantivéssemos a mesma pistola de ar.

No entanto, fique atento: não existe somente o problema de processos não centrados ou somente processos com dispersão excessiva. As duas coisas podem acontecer simultaneamente, o que somente agrava a situação. É necessário, então, estabelecer uma forma de medir a capacidade (ou capacidade) de o processo gerar itens conformes.

Índices de capacidade do processo

Há dois principais índices para medir a capacidade dos processos com relação às especificações:

C_p → mensura somente a dispersão do processo com relação às especificações do produto e

C_{pk} → mensura conjuntamente a dispersão e a centralização do processo com relação às especificações do produto.

A razão de tal separação se deve ao fato de que, como discutido no exemplo dos alvos, se a dispersão for excessiva, será difícil garantir peças conformes. Assim, o C_p mede a capacidade potencial do processo, isto é, o grau de adequação que o processo pode alcançar, caso esteja centrado. Já o C_{pk} mede a capacidade real, isto é, considerando simultaneamente o efeito da dispersão e descentralização.

Podemos, assim, resumir as possibilidades dos dois índices, como mostrado a seguir:

Quadro 10.1: Possibilidades dos dois índices: Cp e Cpk

Cpk	Alto	Não existe	Monitorar
	Baixo	Atuar no processo para reduzir dispersão (aumentar Cp) e somente depois atuar no Cpk	Centralizar processo para aumentar Cpk
		Baixo	Alto
		Cp	

Mas, como são calculados o CP e o Cpk?

O cálculo do Cp é bastante simples: você precisa somente verificar o quão bem o intervalo entre os limites naturais do processo “se encaixa” no intervalo entre as especificações. O ideal é que ele “encaixe” com muita folga, ou seja, que a variabilidade do processo seja mínima quando comparada com o intervalo total das especificações.

Vamos tomar como exemplo a primeira situação estudada de nossa peça e seu processo produtivo, em que a especificação é entre 9,90 mm e 10,10 mm (ou seja, um intervalo de 0,20 mm) e os limites naturais do processo estão entre 9,90 mm e 10,02 mm (intervalo de 0,12 mm). Observe que o intervalo da especificação é maior que o dos limites naturais do processo. Ou seja, “encaixa com folga”.

Na verdade, podemos fazer uma conta bem simples: se dividirmos o intervalo de 0,20 mm pelo de 0,12 mm, chegamos à conclusão de que o intervalo dos limites naturais do processo cabe 1,67 vezes no intervalo da especificação.

Pois bem, essa é a forma de calcular o Cp. A fórmula em sua forma usual é apresentada a seguir:

$$Cp = \frac{LSE - LIE}{LNS - LNI}$$

Alternativamente, podemos representar o cálculo do Cp da seguinte forma:

$$Cp = \frac{LSE - LIE}{6\sigma}$$

Visto que o afastamento total entre os limites naturais é de seis desvios-padrões (± 3 para cada lado), temos:

$$Cp = \frac{10,10 - 9,90}{10,02 - 9,90} \approx 1,67$$

Observe que um alto valor de Cp , ainda que desejável, não significa que haja garantia de peças conformes, pois o processo pode não estar centrado. Assim, um alto Cp indica tão-somente que *potencialmente* podemos garantir peças conformes, desde que consigamos trazer o processo para uma posição centralizada, o que é mais fácil do que garantir bons resultados em um processo cuja dispersão é excessiva com relação às especificações. Como no exemplo dos dois alvos atingidos por pistolas de ar, para conseguir bons resultados no alvo da direita, bastaria “baixar” um pouco a pistola, ao passo que, no alvo da esquerda, isso seria bem mais difícil, pois não há precisão nos tiros.

Já a lógica de cálculo do Cpk é diferente, pois não queremos saber somente da potencialidade do processo, mas sim do seu real resultado, como está. Assim, um processo com Cp baixo causará, também, um Cpk baixo. Mas um Cp alto não é garantia de um Cpk alto, pois, como dito anteriormente, o processo pode não estar centrado.

Assim, podemos dizer que o cálculo do Cpk , grosso modo, que é o cálculo da capacidade do processo “para ambos os lados”. Ou seja, em um processo não centralizado, temos um dos lados da distribuição que estará mais próximo do limite da especificação (ou até mesmo o ultrapassará) do que o outro. Assim, a nossa maior preocupação não recai sobre o lado em que há mais “folga”, mas sim sobre o lado em que corremos mais risco de termos não conformidades.

Repare, por exemplo, na **Figura 10.4**: devemos nos preocupar mais com a possibilidade de as peças produzidas terem uma dimensão maior do que 10,10 mm ou menor do que 9,90 mm? Olhe a figura e reflita...

Obviamente, nossa preocupação está em ficarmos abaixo do limite inferior da especificação: estamos próximo demais dele (na verdade, há uma coincidência, nesse exemplo, entre o limite da especificação e o limite natural do processo). Assim sendo, o Cpk leva em consideração a capacidade do processo para cada lado das especificações: ambos são calculados e a medida do Cpk é dada pela pior situação (obviamente, em um processo centrado, as distâncias serão idênticas e, conseqüentemente, a medida do Cpk pode ser feita em qualquer dos lados).

Veja a fórmula de cálculo do CpK a seguir:

$$Cpk = \text{Mín} \left[\frac{LSE - \mu}{3\sigma}; \frac{\mu - LIE}{3\sigma} \right]$$

Sendo μ o valor médio do processo (sua LC).

Vamos resolver o problema apresentado por Peinado e Graelm (2007), calculando o Cpk e o Cp do processo:

Um fabricante de eixos cilíndricos deseja produzir, no processo com LSC = 10,4; LC = 10,0 e LIC = 9,6, eixos em que a especificação de medida do diâmetro seja de $10,5 \pm 0,6$ mm. Bem, para calcular o Cpk, precisamos identificar o LSE, o LIE, o valor de μ e o de 3σ . Como a especificação é de $10,5 \pm 0,6$ mm, o LSE é 11,1 mm e o LIE é 9,9mm. O valor de μ é fornecido no enunciado (10,0 mm). E como o afastamento total dos limites naturais do processo é de 0,8 mm ($10,4 - 9,6 = 0,8$), o que representa $\pm 6\sigma$, temos que $3\sigma = 0,4$ mm.

Desta forma, podemos calcular o Cpk, como mostrado a seguir:

$$Cpk = \text{Mín} \left[\frac{11,1 - 10,0}{0,4}; \frac{10,0 - 9,9}{0,4} \right] = \text{Mín} \left[\frac{1,1}{0,4}; \frac{0,1}{0,4} \right] = \text{Mín} [2,75; 0,25]$$

Assim, o CpK do processo é de 0,25 (menor valor). Observe que o Cp do mesmo processo é alto:

$$Cp = \frac{11,1 - 9,9}{0,8} = 1,5$$

Ou seja, é um processo que teria grande potencial para gerar peças conformes. No entanto, ele está muito descentralizado: repare que encontramos 2,75 “de um lado” e 0,25 “do outro lado” e isso pode ser visualizado na imagem a seguir.

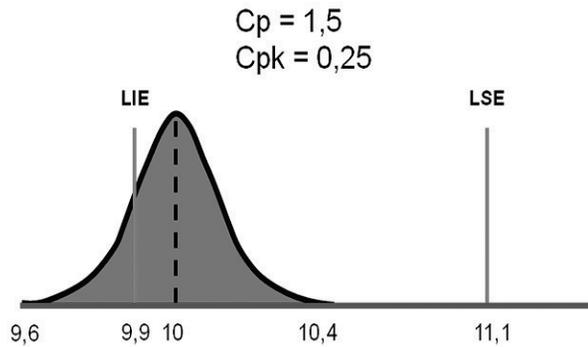


Figura 10.9: Limites de especificação e limites do processo. Observe como o processo está muito capaz do lado do limite superior da especificação, pois há muita folga entre o limite natural do processo e o limite da especificação (o que é evidenciado pelo valor de 2,75), ao passo que o limite natural inferior do processo chega a avançar para além do limite inferior da especificação (medida de 0,25). Consequentemente, é de se esperar uma grande proporção de peças não conformes produzidas, com medidas inferiores ao limite inferior da especificação.

Fonte: Adaptado de Peinado & Graeml (2007).

Veja a lógica do cálculo do C_{pk} : encontramos, de um lado, 2,75 e do outro, 0,25, não é mesmo? A média desses valores seria $(2,75 + 0,25)/2 = 1,5$, que é o próprio valor de C_p . Assim, quando temos um processo perfeitamente centrado, $C_{pk} = C_p$.

Mas quais seriam os valores aceitáveis ou adequados para C_p e, principalmente, C_{pk} ? Bem, o valor “1” é o mínimo aceitável, pois os limites naturais coincidiriam com os limites das especificações, gerando 0,27% de não conformidades. Observe, na figura a seguir, algumas possibilidades quanto ao C_p e C_{pk} para diferentes processos.

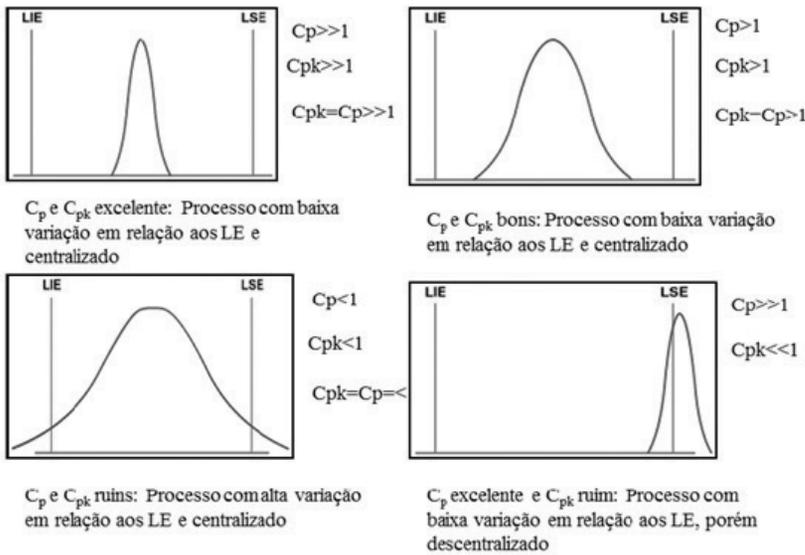


Figura 10.10: Processo capaz e não capaz. Observe como um processo com alta dispersão ultrapassa os limites de especificação, mesmo que esteja centralizado (canto esquerdo inferior), ao passo que um processo não centrado também pode ter tal problema, mesmo que seu Cp seja alto.

Fonte: Ribeiro e Caten (2012, p. 57).

Costa, Epprecht e Carpinetti (2016) e Bonifácio e Vasconcellos ([2004?]) estabeleceram uma classificação de processos com respeito à sua capacidade, como mostrado a seguir.

Tabela 10.1: Classificação de processos quanto a sua capacidade

Classificação	C _{pk}	Itens fora da especificação (partes por milhão)	
		Especificação bilateral e processo centrado	Processo não centrado e/ou especificação unilateral
Capaz	≥ 1,33	70	35
Razoavelmente capaz	1 ≤ C _{pk} < 1,33	Entre 70 e 2.700	Entre 35 e 1.350
Incapaz	< 1	> 2.700	> 1.350

De acordo com Ribeiro e Caten (2012, p. 60): “O cálculo do percentual de peças fora de especificação é estimado calculando-se a média e a variabilidade da distribuição e o valor da variável reduzida Z para os limites de especificação”. Para tanto, calculamos os afastamentos medidos em quantidade de desvios-padrões, como mostrado na fórmula a seguir:

$$Z = \frac{LE - \mu}{\sigma}$$

Por exemplo, se considerarmos os dados de Peinado e Graelm (2007), constantes na **Figura 10.9**, temos: do “lado esquerdo” (limite inferior da especificação), como temos: LIE = 9,9 e $\mu = 10,0$, com $\sigma = 1,33$ ($0,4/3 = 1,33$), o valor de Z será:

$$Z = \frac{9,9 - 10,0}{1,33} = -0,75$$

Utilizando a função DIST.NORMP do Excel, calculamos que a probabilidade acumulada é de 0,2266. Ou seja, a expectativa é que tenhamos 22,66% das peças não conformes, com dimensão abaixo do limite inferior da especificação.

Por outro lado, ao analisarmos o “lado direito” (no sentido do limite superior da especificação), a folga observada nos traz um cenário completamente diferente: como temos LSE = 11,1 e $\mu = 10,0$, com $\sigma = 1,33$, o valor de Z será:

$$Z = \frac{11,1 - 10,0}{1,33} = 8,25$$

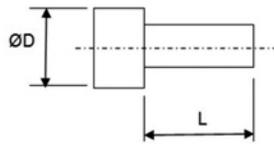
A consulta à função DIST.NORMP do Excel para tal valor nos indica que é virtualmente impossível termos peças fora do limite superior, isto é, 100% delas (dentro da capacidade de cálculo do Excel) estaria abaixo de 11,1 mm. Tal inferência faz sentido, visto que a medida se encontra afastada da média do processo mais de oito desvios-padrões, de tal forma que ocorrências além deste limite tenderiam a zero.

Assim sendo, podemos calcular a capacidade de processos diversos, tendo por base os resultados dos processos e as especificações do projeto: a capacidade potencial (pelo Cp) e a capacidade real (Cpk). Além disso, podemos prever a proporção de peças não conformes, informação que poderia ser utilizada para disparar ações de melhoria de processos e/ou aspectos de garantia.

Atividade

Atende ao objetivo 2

No conteúdo desta aula, você aprendeu como analisar a capacidade dos processos. Utilizamos o exemplo da peça mostrada a seguir e foi informado que o processo está gerando peças cuja medida média do diâmetro é de 9,96 mm e que o desvio-padrão é de 0,02mm.



ØD (mm)
10,00 ±0,10

Assumindo ser um processo estável, isto é, sem pontos fora dos limites de controle, com valores respeitando a distribuição normal e sem padrões estatisticamente improváveis, calcule a capacidade potencial e real do processo, diga como tal processo pode ser classificado, calcule a proporção esperada de peças não conformes que serão geradas por ele e faça recomendações para melhoria de tais proporções.

Resposta comentada

Calculando o Cpk:

$$Cpk = \text{Mín} \left[\frac{10,0 - 9,96}{0,06}; \frac{9,96 - 9,90}{0,06} \right] = \text{Mín} [2,33; 1] = 1$$

De acordo com a classificação estabelecida por Costa, Epprecht e Carpinetti (2016) e Bonifácio e Vasconcelos ([2004?]), mostrada a seguir, o processo seria classificado como “razoavelmente capaz”.

Classificação	Cpk
Capaz	$\geq 1,33$
Razoavelmente capaz	$1 \leq Cpk < 1,33$
Incapaz	< 1

Calculando o Z, temos:

$$Z = \frac{LE - \mu}{\sigma} = \frac{9,90 - 9,96}{0,02} = -3$$

Utilizando a função DIST.NORMP do Excel, identificamos que a proporção de peças abaixo do limite inferior da especificação, isto é, menores do que 9,90 mm, é de 0,13%.

Calculando o Cp:

$$Cp = \frac{LSE - LIE}{LNS - LNI} = \frac{10,10 - 9,90}{10,02 - 9,90} = 1,667$$

Como pode ser observado no valor do Cp, o processo tem grande potencial de melhoria: para tanto, seria adequado que se buscasse uma melhor centralização deste. Se a centralização fosse exata, o Cpk poderia alcançar o valor de 1,67 (isto é, o mesmo valor do Cp). Com isso, o valor de Z chegaria a:

$$Z = \frac{LE - \mu}{\sigma} = \frac{9,90 - 10,00}{0,02} = -5$$

Utilizando a função DIST.NORMP do Excel, identificamos que a proporção de peças acima ou abaixo dos limites da especificação seria de 0,00003%. Uma melhoria substancial!

Conclusão

A razão final de utilizarmos os gráficos de controle é a de podermos monitorar os processos produtivos e nos certificarmos de que estes produzam peças que estão de acordo com as especificações de projeto.

O controle estatístico por si só, com a definição dos limites de controle nos gráficos, bem como as verificações de normalidade dos dados e a não existência de padrões estatisticamente improváveis nos mostra que os processos são estáveis, previsíveis, por estarem submetidos somente a causas comuns. Mas isso não garante que consigamos obter somente peças conformes: é preciso avaliar a capacidade do processo, o que é feito pelos indicadores Cp e Cpk, que comparam os resultados dos processos com as especificações de projeto.

Ou seja, podemos ter processos estáveis, mas que, mesmo assim, não são capazes, por não conseguirem garantir as especificações.

A falta de estabilidade do processo e/ou baixos índices de capacidade exigem que sejam tomadas ações para identificar as causas-raiz do problema e estabelecer quais ações seriam adequadas. Para tanto, podem ser utilizadas ferramentas como o diagrama PDCA, o diagrama de causa e efeito, etc.

Resumo

A criação do controle estatístico de processos permitiu que pudéssemos nos antecipar a diversos problemas: mudanças detectadas nos processos por meio dos gráficos de controle nos levam a iniciar um processo de investigação, para identificar a causa-raiz de tais mudanças e como elas influenciariam a qualidade das peças produzidas.

Para ampliar as possibilidades de análise, podemos, também, utilizar os cálculos estatísticos utilizados para construir os gráficos para mensurar a capacidade dos processos de produzirem peças conformes. Isso é feito por meio de dois índices: o Cp, que mede a capacidade potencial de um processo, e o Cpk, que mede a capacidade real.

Tais indicadores só deverão ser utilizados após nos certificarmos de que temos um processo estável, isto é, que não está submetido a causas especiais. A evidência de tal situação é refletida em não haver pontos nos gráficos que estão fora dos limites de controle estabelecidos, que a distribuição dos dados segue o padrão normal e que não há comportamentos estatisticamente improváveis nas sequências de dados.

O Cp é calculado da seguinte forma:

$$Cp = \frac{LSE - LIE}{LNS - LNI}$$

Sendo LSE e LIE os limites superior e inferior da especificação e LNS e LNI os limites naturais (respectivamente, superior e inferior) do processo, ou seja, variações de $\pm 3\sigma$ do valor central do mesmo.

O Cpk é calculado da seguinte forma:

$$Cpk = \text{Mín} \left[\frac{LSE - \mu}{3\sigma}; \frac{\mu - LIE}{3\sigma} \right]$$

Sendo μ o valor médio do processo (sua LC).

Os processos são classificados, de acordo com a sua capacidade, podendo ser capazes, razoavelmente capazes ou incapazes. A partir da determinação da capacidade do processo, é possível estimar a proporção de peças não conformes. Para isso, é necessário calcular a quantidade de afastamentos medida em desvios-padrões (Z), utilizando a seguinte fórmula:

$$Z = \frac{LE - \mu}{\sigma}$$

Encontrado o valor de Z, podemos utilizar a função DIST.NORMP do Excel, para identificamos a proporção prevista de peças fora dos limites de especificação.

Leitura recomendada

GONÇALEZ, Patricia Ueda; WERNER, Liane. Comparação dos índices de capacidade do processo para distribuições não-normais. *Gestão & Produção*, São Carlos, v. 16, n. 1, p. 121-132, jan./mar. 2009. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104-530X2009000100012&lng=en&nrm=iso. Acesso em: 10 abr. 2019.

Informação sobre a próxima aula

Na próxima aula, estudaremos os conceitos e técnicas de inspeção, em especial, os planos de amostragem de aceitação de lotes.

Referências

BONIFÁCIO, Teresa Cristina Cortês; VASCONCELLOS, Luís Henrique Rigato. *Gerenciamento estatístico do processo*. São Bernardo do Campo: QA – Central, [2004?].

CHRISTO, E. S. *Aula 10 – Análise da estabilidade e capacidade do processo*. Curso: Engenharia de Produção. Disciplina: Controle Estatístico da Qualidade. Material de apoio (Semana 10), Plataforma Cederj, 2017. Disponível em: <https://graduacao.cederj.edu.br/ava/course/view.php?id=1404§ion=13>. Acesso em: 28 jun. 2019.

COSTA, Antônio Fernando Branco; EPPRECHT, Eugenio Kahn; CARPINETTI, Luiz César Ribeiro. *Controle estatístico de qualidade*. 2. ed. São Paulo: Atlas, 2016.

PEINADO, Jurandir; GRAEML, A. Reis. *Administração da produção: operações industriais e de serviços*. Curitiba: UnicenP, 2007.

RIBEIRO, José Luis Duarte; CATEN, Carla Schwengber ten. *Controle estatístico do processo: cartas de controle para variáveis, cartas de controle para atributos, função de perda quadrática, análise de sistemas de medição*. Série monográfica Qualidade. Porto Alegre: FEENG/UFRGS – Fundação Empresa Escola de Engenharia da UFRGS – Universidade Federal do Rio Grande do Sul, 2012.

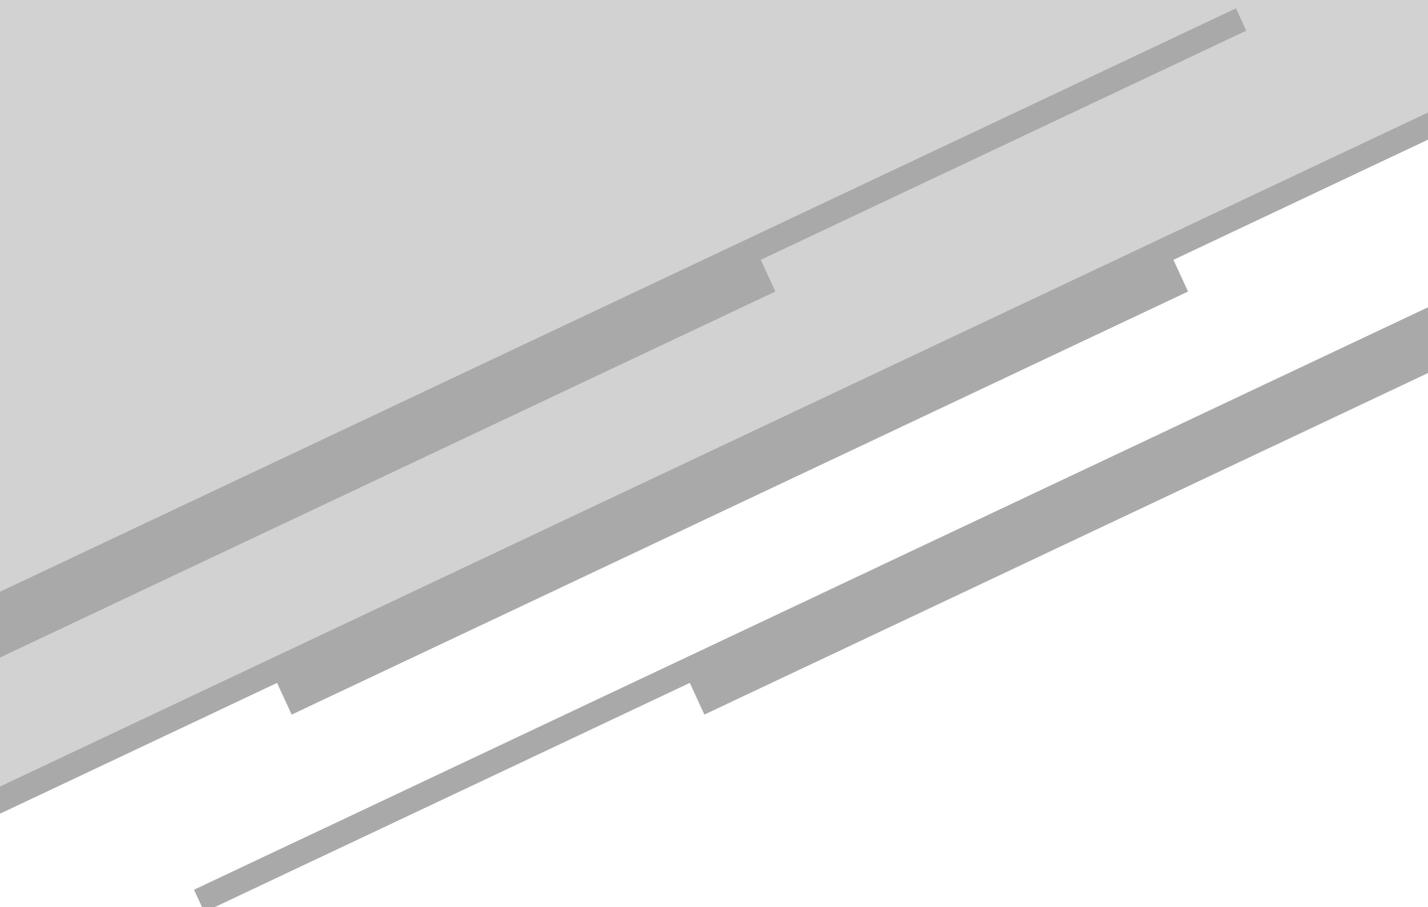
ROCHA, Henrique Martins. *Fatores críticos de sucesso do start up de veículos e a qualidade (CMMI) do desenvolvimento de produtos no Sul Fluminense*, 2005, 353f. Dissertação (Mestrado em Sistemas de Gestão). Universidade Federal Fluminense, Niterói, 2005.

SILVA, Rouverson P. da et al. Controle estatístico aplicado ao processo de colheita mecanizada de cana-de-açúcar. *Engenharia Agrícola*, Jaboticabal, v. 28, n. 2, p. 292-304, abr./jun. 2008. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162008000200010&lng=en&nrm=iso. Acesso em: 9 abr. 2019.

SONDAGENS E ESTUDOS DE OPINIÃO. *Estatística descritiva*. Escola Superior de Educação do Politécnico de Coimbra, 25 nov. 2012. Disponível em: <https://sondagenseestudosdeopiniao.wordpress.com/estatistica/estatistica-descritiva/>. Acesso em: 3 jan. 2019.

Aula 11

Inspeção da qualidade



Henrique Martins Rocha

Metas

Relembrar algumas distribuições de probabilidade usadas em uma inspeção de qualidade; apresentar planos de amostragem de aceitação lote a lote para atributos e mostrar a inspeção de retificação.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. conforme o número de itens defeituosos na amostra, aceitar ou rejeitar o lote;
2. determinar o plano de amostragem que mais se adequa ao problema.

Pré-requisitos

Funções estatísticas e distribuição normal; distribuição binomial; causas comuns e causas especiais; gráficos de controle, conteúdos abordados nas aulas anteriores.

Introdução

Além do monitoramento de processos pelas cartas de controle e do uso de ferramentas da qualidade para manter e melhorar a qualidade de produtos e processos, em determinadas situações, é preciso inspecionar lotes de peças e produtos recebidos dos fornecedores, de forma a garantir que sejam aceitáveis.

Mas, mesmo em situações como essas, o uso de análises estatísticas traz grande auxílio, permitindo que tais inspeções ocorram por amostragem e que, a partir dos resultados, isto é, da quantidade de peças não conformes encontradas, possamos fazer inferências sobre a qualidade do lote recebido e que tomemos decisões sobre ele: aceitar ou devolver.

É isso que você estudará aqui: você aprenderá sobre os procedimentos para tais inspeções e os critérios de aceitação e rejeição dos lotes. Bons estudos!

Como você aprendeu na Aula 1, a qualidade passou por diversas fases, sendo um dos saltos mais importantes a substituição da denominada inspeção 100% pelo controle estatístico da qualidade, em que buscamos nos antecipar aos problemas, mediante o monitoramento dos processos produtivos, de tal forma que variações anormais servissem como um alerta, indicando que algo havia mudado no processo e que, consequentemente, peças não conformes poderiam ser produzidas a partir daí.

Mas, as técnicas de controle estatístico tiveram, também, o reforço das chamadas “técnicas de amostragem”. Como você viu na Aula 1, os pesquisadores Harold French Dodge (1893-1976) e Harry Gutelius Romig (1874-1948), da Bell Telephone Laboratories, desenvolveram os conceitos de amostragem para aceitação de lotes.



Figura 11.1: Inspeção de uma placa de circuito impresso e seus componentes. Testes e inspeções são atividades comuns na área industrial. No entanto, são atividades custosas e muitas vezes demoradas, devendo haver um balanço entre as preocupações com a qualidade e o custo do processo produtivo. Fonte: https://www.freepik.com/free-photo/male-technician-examining-computer-motherboard-with-digital-multimeter_3334122.htm

“A alternativa para a inspeção 100% é a inspeção por amostragem, que reduz o tempo e os custos de inspeção” (COSTA; EPPRECHT; CARPINETTI, 2016, p. 236). Mas como decidir como deve ser a amostragem? Qual deve ser o tamanho da amostra? Qual deve ser o critério de aceitação ou de rejeição de lotes? Vamos compreender como são feitas tais análises.

Inspeção para aceitação

De acordo com Besterfield (1990), a inspeção por amostragem é recomendada em cinco situações:

1. Quando o teste é destrutivo (exemplo: testes de fusíveis ou testes de resistência à tensão).
2. Quando o custo da inspeção 100% é maior que o custo referente à existência de unidades defeituosas.
3. Quando há muitas peças similares a serem inspecionadas. Neste caso, os resultados da inspeção por amostragem são até melhores que uma inspeção 100%, devido ao efeito de fadiga e tédio no processo de inspeção.

4. Quando informações sobre a qualidade do processo produtivo do fornecedor (exemplo: cartas de controle) não estão disponíveis.
5. Quando não é possível uma inspeção automática.

É importante lembrar que, quando falamos de amostragem, estamos falando de probabilidades, isto é, a probabilidade de nossas inferências sobre aprovar ou não peças ou lotes ser “correta” ou não. Lembre-se, por exemplo, que os próprios limites de um gráfico de controle não são garantia de exatidão nas análises: há uma probabilidade diminuta de termos pontos fora dos limites sem que sejam, de fato, sinal de causas especiais no processo (vide Aulas 6 e 7). E, também, ter todos os pontos dentro dos limites não é garantia de termos um processo sob controle.

Desta forma, como defendido por Costa, Epprecht e Carpinetti (2016), há sempre riscos envolvidos no processo por amostragem, quais sejam:

Risco α : o chamado risco do produtor, referente à probabilidade de rejeição de um lote de um processo de “boa qualidade”, isto é, em que a proporção de peças defeituosas é igual ou inferior ao esperado em bases estatísticas (lembre-se de que, se trabalhamos com probabilidades, não podemos ter 100% de certeza sobre a qualidade).

Risco β : o denominado risco do consumidor, que diz respeito à aceitação de um lote de um processo cuja proporção de itens defeituosos seja superior ao esperado.

Nessas situações, temos somente duas possíveis situações: defeito ou não defeito, ou ainda, quantidade de peças defeituosas acima ou abaixo de esperado. Assim sendo, Doane e Seward (2014) recomendam o balanceamento de tais riscos, de tal forma que não haja rigor excessivo para um lado ou para o outro:

Na sua forma mais simples, a amostragem de um lote tem por base a distribuição hipergeométrica, na qual amostras sem reposição de n itens são selecionadas de um lote de tamanho N contendo s itens não conformes. Curvas de poder e curvas características de operação podem ser construídas para orientar as decisões a respeito da aceitação ou da rejeição de remessas, com base no atributo de interesse (usualmente, a proporção de itens não conformes) (DOANE; SEWARD, 2014, p. 743).

Já a quantidade de itens defeituosos do lote, de acordo com Costa, Epprecht e Carpinetti (2016), segue uma distribuição binomial, como

you studied in Aula 8. But, as an example of the logic developed by Shewhart for control charts, where complex statistical calculations were replaced by tables of variables, to facilitate calculation (see Aula 6), the same happens with sample sizes and acceptance criteria: specific standards establish such criteria. Next, you find the main standards of the Brazilian Association of Technical Standards (ABNT) with this purpose:

- ABNT NBR 5425:1985 – Guia para inspeção por amostragem no controle e certificação de qualidade. O objetivo geral desta norma é consubstanciar as regras e recomendações que devem ser aplicadas pelos órgãos responsáveis pelo controle e certificação de qualidade;
- ABNT NBR 5426:1985 – Planos de amostragem e procedimentos na inspeção por atributos. Esta norma estabelece planos de amostragem e procedimentos para inspeção por atributos. Quando especificada pelo responsável, esta norma deve ser citada em contratos, instruções ou outros documentos, e as determinações estabelecidas devem ser obedecidas;
- ABNT NBR 5427:1985 – Guia para utilização da norma ABNT NBR 5426 – Planos de amostragem e procedimentos na inspeção por atributos. Esta norma fornece instruções detalhadas e exemplos ilustrativos para aplicação e administração dos procedimentos de amostragem por atributos estabelecidos pela ABNT NBR 5426;
- ABNT NBR 5428:1985 – Procedimentos estatísticos para determinação da validade de inspeção por atributos feita pelos fornecedores. Esta norma estabelece testes estatísticos apropriados e tabelas de valores críticos para uso na determinação da validade dos resultados registrados nos relatórios de inspeção do fornecedor, quando for especificada inspeção por amostragem por atributos. Tais registros asseguram ao consumidor que a qualidade dos fornecimentos está de acordo com os requisitos técnicos.
- ABNT NBR 5429:1985 – Planos de amostragem e procedimentos na inspeção por variáveis: Esta norma estabelece planos de amostragem e procedimentos para inspeção por variáveis. Quando especificada pelo responsável, a presente norma deve ser citada em contratos, instruções ou outros documentos, e as determinações estabelecidas deverão ser obedecidas;
- ABNT NBR 5430:1985 – Guia de utilização da norma ABNT NBR 5429 – Planos de amostragem e procedimentos na inspeção por

variáveis. Esta norma tem por finalidade fornecer instruções detalhadas, com exemplos ilustrativos, para aplicação e administração dos procedimentos de amostragem por variáveis estabelecidos na ABNT NBR 5429.



O catálogo completo das normas ABNT pode ser consultado no seguinte endereço: <https://www.abntcatalogo.com.br/>.

Na verdade, o uso de tabelas para facilitar os cálculos não é a única semelhança entre os planos de inspeção para aceitação e os gráficos de controle da qualidade: a definição do tamanho da amostra, com base na probabilidade de detecção de problemas, tem similaridade com o conceito de poder de detecção que você aprendeu na Aula 7. E a quantidade máxima de peças defeituosas para aceitação do lote tem clara relação com o limite superior de controle dos gráficos de controle que você estudou nas Aulas 6 a 9.

Vantagens e desvantagens da inspeção por amostragem

De acordo com Besterfield (1990) e Montgomery (2001), temos as seguintes vantagens da inspeção por amostragem, quando comparada com a inspeção 100%:

Vantagens

- coloca a responsabilidade sobre a qualidade no local correto, ao invés de sobre o pessoal de inspeção, propiciando rápida melhoria do produto;
- mais econômica, com menos inspeções e menos inspetores, além de reduzir danos por manuseio durante a inspeção;
- aprimoramento do trabalho de inspeção, migrando da monótona rotina de inspecionar peça a peça para decisões sobre lotes;
- é aplicável a testes destrutivos;

- rejeição de lotes inteiros, ao invés de somente devolver peças não conformes, o que motiva a melhoria dos processos.

Desvantagens

- há risco de aceitar lotes de “má qualidade” e rejeitar lotes de “boa qualidade”;
- consome mais tempo de planejamento e documentação;
- há menos informações sobre o produto;
- não há segurança de que todo o lote esteja de acordo com as especificações.

Cabe destacar que a tendência atual é a de substituir a inspeção de recebimento para aceitação por uma atuação proativa junto aos fornecedores, certificando seus processos para que assegurem a qualidade de seus produtos (COSTA; EPPRECHT; CARPINETTI, 2016). Desta forma, a inspeção de aceitação permanece em uso, basicamente, para novos fornecedores ou novos produtos de cada fornecedor, sendo utilizada como uma fase transitória, desde o início do fornecimento até que se conclua a certificação dos processos produtivos dos produtos dos fornecedores.

Plano de amostragem simples

No processo de inspeção por amostragem, de acordo com Costa, Epprecht e Carpinetti (2016), é retirada uma amostra do lote e esta é inspecionada, peça a peça. Nesse sentido, Besterfield (1990) alerta que os lotes devem ser homogêneos: peças produzidas pela mesma máquina, mesmo operador, com a mesma matéria-prima, etc. Além disso, é importante que a amostra seja coletada de forma randômica, para garantir que ela seja representativa do lote. Por exemplo, se coletarmos as unidades de amostra somente da camada superior de um pacote, cesto ou qualquer outra forma de embalagem, estaremos provavelmente coletando peças muito parecidas e deixando de inspecionar peças que podem ter diferenças significativas. Lembre-se de que, como estudado na Aula 6, nas peças que estão “em sequência” é provável que elas sejam muito parecidas, ao passo que peças produzidas

com intervalo maior podem ser bem diferentes, devido à possibilidade de ocorrência de causas especiais.

Desta forma, é comum que se utilize programas de computador ou tabelas de números aleatórios, para garantir que as unidades selecionadas sejam, de fato, aleatórias. Veja, por exemplo, a proposta de Besterfield (1990), mostrada na **Figura 11.2**, em que a geração de números aleatórios com três dígitos poderia servir de base para coleta da amostra, em que o primeiro dígito representaria a largura (w), o segundo, a altura (h) e o terceiro, a profundidade (d).

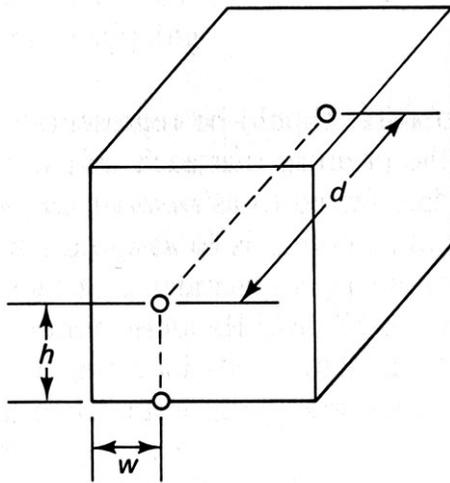


Figura 11.2: Localização e números randômicos. Quando as unidades de um lote são embaladas de acordo com um padrão geométrico específico, é possível utilizar números aleatórios para auxiliar no processo de seleção das unidades da amostra. Por exemplo, adotando um padrão “whd”, o número aleatório 328 nos indicaria que deveríamos selecionar a unidade que estivesse na terceira fileira (da esquerda para a direita), segunda camada (de baixo para cima) e oitava posição (da frente para trás).

Fonte: BESTERFIELD (1990, p. 206).

Uma vez inspecionada a amostra, a quantidade de peças rejeitadas (d) é comparada com uma quantidade tabelada (A_c , que representa a forma abreviada de “aceitar”): se maior que esta, ou seja, se $d > A_c$, o lote é rejeitado (as tabelas indicam a quantidade Re , a partir da qual o lote é rejeitado) e devolvido ao produtor. Caso contrário (se $d \leq A_c$), o lote é aceito.

O plano de amostragem, isto é, o tamanho da amostra (n) é definido a partir do tamanho do lote e do nível de inspeção estabelecido. De acordo com a norma NBR 5426 (ABNT, 1985), há três níveis gerais e quatro níveis especiais de inspeção (respectivamente, I, II, III, S1, S2, S3 e S4). Costa, Epprecht e Carpinetti (2016) explicam tais níveis:

Salvo indicação contrária, deve-se adotar o nível de inspeção II. O nível I pode ser utilizado quando for necessário diminuir o tamanho da amostra (ao preço de aumentar o risco β , do consumidor) e o nível III quando for necessário reduzir o risco do consumidor (ao preço de aumentar o tamanho da amostra). Há ainda quatro níveis especiais [...], para os casos em que só se podem usar tamanhos de amostra muito pequenos (por exemplo, no caso de ensaios destrutivos muito caros) e em que possam e devam ser tolerados grandes riscos de amostragem (p. 250).

Determinação do plano de amostragem

O processo se inicia, assim, com a definição do tamanho da amostra, tomando por base o tamanho do lote e segue com a definição da quantidade aceitável de peças defeituosas. Mas, para isso, precisamos estabelecer o nível de qualidade aceitável (NQA) da análise, isto é, o nível de confiança que queremos e, conseqüentemente, a significância estatística (α) da análise da amostra. A norma NBR 5426 (ABNT, 1985) estabelece valores de NQA a partir de 0,010%.

Precisamos, também, estabelecer se deve ser uma inspeção normal, severa ou atenuada: iniciando pela inspeção normal, se o histórico do fornecedor é bom (10 lotes consecutivos aceitos), pode-se passar a fazer a inspeção atenuada, reduzindo o tamanho das amostras. Por outro lado, se o histórico do fornecedor não gera confiança (dois em cinco lotes consecutivos rejeitados), passa-se à inspeção severa, com o

aumento do tamanho da amostra. Costa, Epprecht e Carpinetti (2016) detalham a dinâmica de mudanças dos tipos de inspeção, como mostrado na **Figura 11.3**.

Repare na citada figura que há critérios não somente para migrar da inspeção normal para atenuada ou severa, como há, também, critérios para migrar destas, retornando à inspeção normal.

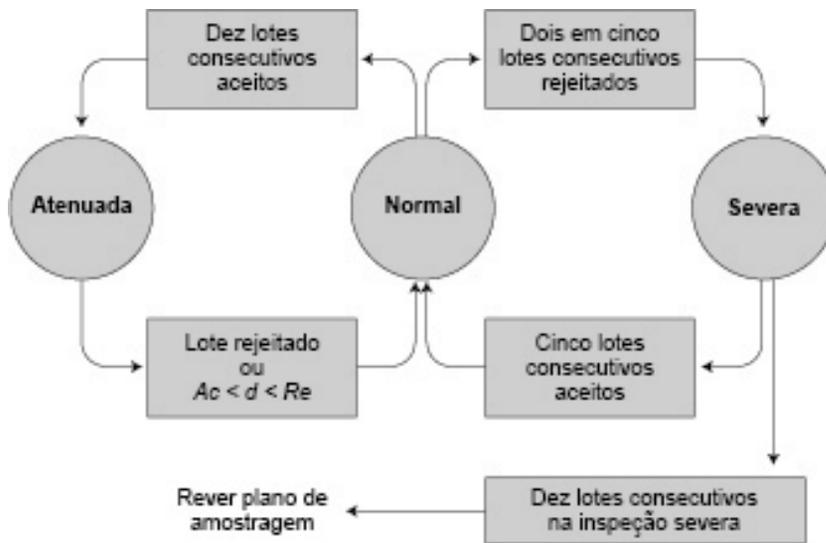


Figura 11.3: Regras gerais para comutação entre os modos de inspeção. Repare que o desempenho do fornecedor, ou seja, da aceitação ou rejeição de seus lotes, vai fazer com que a inspeção aplicada nos lotes recebidos possa ser modificada. Obs: a situação de $Ac < d < Re$ será discutida posteriormente, quando estudarmos o plano de amostragem dupla.

Fonte: COSTA; EPPRECHT; CARPINETTI (2016, p. 253).

De acordo com a ABNT (1985), se o fornecedor não consegue sair da situação de inspeção severa (por exemplo, por 10 lotes consecutivos), é recomendado interromper a inspeção efetuada sob as diretrizes da NBR 5426:1985, até que sejam adotadas providências para aprimoramento da qualidade do produto.

As tabelas a seguir apresentam os tamanhos de amostra e os valores limites de aceitação (Ac) e rejeição (Re), considerando o nível geral de inspeção II e NQA de 0,10%, 0,15%, 0,25%, 1,0%, 2,5% e 10% (para outros níveis de inspeção e NQA, consulte a NBR 5426:1985).

Tabela 11.1: Plano de amostragem normal para nível de inspeção geral II

Tamanho do lote	Tamanho da amostra	NQA											
		0,10		0,15		0,25		1,0		2,5		10	
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re
2 a 8	2	0	1	0	1	0	1	0	1	0	1	1	2
9 a 15	3	0	1	0	1	0	1	0	1	0	1	1	2
16 a 25	5	0	1	0	1	0	1	0	1	0	1	1	2
26 a 50	8	0	1	0	1	0	1	0	1	0	1	2	3
51 a 90	13	0	1	0	1	0	1	0	1	1	2	3	4
91 a 150	20	0	1	0	1	0	1	0	1	1	2	5	6
151 a 280	32	0	1	0	1	0	1	1	2	2	3	7	8
281 a 500	50	0	1	0	1	0	1	1	2	3	4	10	11
501 a 1.200	80	0	1	0	1	0	1	2	3	5	6	14	15
1.201 a 3.200	125	0	1	0	1	1	2	3	4	7	8	21	22
3.201 a 10.000	200	0	1	1	2	1	2	5	6	10	11	21	22
10.001 a 35.000	315	1	2	1	2	2	3	7	8	14	15	21	22
35.001 a 150.000	500	1	2	2	3	3	4	10	11	21	22	21	22
150.001 a 500.000	800	2	3	3	4	5	6	14	15	21	22	21	22
Acima de 500.000	1.250	3	4	5	6	7	8	21	22	21	22	21	22

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p. 8) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 282).

Tabela 11.2: Plano de amostragem severa para nível de inspeção geral II

Tamanho do lote	Tamanho da amostra	NQA											
		0,10		0,15		0,25		1,0		2,5		10	
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re
2 a 8	2	0	1	0	1	0	1	0	1	0	1	1	2
9 a 15	3	0	1	0	1	0	1	0	1	0	1	1	2
16 a 25	5	0	1	0	1	0	1	0	1	0	1	1	2
26 a 50	8	0	1	0	1	0	1	0	1	0	1	1	2
51 a 90	13	0	1	0	1	0	1	0	1	1	2	2	3
91 a 150	20	0	1	0	1	0	1	0	1	1	2	3	4

151 a 280	32	0	1	0	1	0	1	1	2	1	2	5	6
281 a 500	50	0	1	0	1	0	1	1	2	2	3	8	9
501 a 1.200	80	0	1	0	1	0	1	1	2	3	4	12	13
1.201 a 3.200	125	0	1	0	1	1	2	2	3	5	6	18	19
3.201 a 10.000	200	0	1	1	2	1	2	3	4	8	9	18	19
10.001 a 35.000	315	1	2	1	2	1	2	5	6	12	13	18	19
35.001 a 150.000	500	1	2	1	2	2	3	8	9	18	19	18	19
150.001 a 500.000	800	1	2	2	3	3	4	12	13	18	19	18	19
Acima de 500.000	1.250	2	3	3	4	5	6	18	19	18	19	18	19

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p. 9) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 283).

Tabela 11.3: Plano de amostragem atenuada para nível de inspeção geral II

Tamanho do lote	Tamanho da amostra	NQA											
		0,10		0,15		0,25		1,0		2,5		10	
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re
2 a 8	2	0	1	0	1	0	1	0	1	0	1	0	2
9 a 15	2	0	1	0	1	0	1	0	1	0	1	0	2
16 a 25	2	0	1	0	1	0	1	0	1	0	1	0	2
26 a 50	3	0	1	0	1	0	1	0	1	0	1	1	3
51 a 90	5	0	1	0	1	0	1	0	1	0	2	1	4
91 a 150	8	0	1	0	1	0	1	0	1	0	2	2	5
151 a 280	13	0	1	0	1	0	1	0	2	1	3	3	6
281 a 500	20	0	1	0	1	0	1	0	2	1	4	5	8
501 a 1.200	32	0	1	0	1	0	1	1	3	2	5	7	10
1.201 a 3.200	50	0	1	0	1	0	2	1	4	3	6	10	13
3.201 a 10.000	80	0	1	0	2	0	2	2	5	5	8	10	13
10.001 a 35.000	125	0	2	0	2	1	3	3	6	7	10	10	13
35.001 a 150.000	200	0	2	1	3	1	4	5	8	10	13	10	13

150.001 a 500.000	315	1	3	1	4	2	5	7	10	10	13	10	13
Acima de 500.000	500	1	4	2	5	3	6	10	13	10	13	10	13

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p. 10) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 284).

Vamos a um exemplo: Para um lote de 6.000 peças, qual deve ser o tamanho da amostra a ser inspecionada e quais os critérios de aceitação/rejeição, considerando uma inspeção normal de nível II e um NQA de 1%?

Resposta: Consultando a **Tabela 11.1**, identificamos que o tamanho da amostra deve ser de 200 unidades (visto que o lote de 6.000 peças está na faixa de 3.201 a 10.000 unidades). Para um NQA = 1%, temos $Ac = 5$ e $Re = 6$. Ou seja, se dentre as 200 unidades inspecionadas encontrássemos um máximo de cinco peças defeituosas, o lote deveria ser aceito, ao passo que, com seis ou mais peças defeituosas, o lote deveria ser rejeitado e devolvido ao fornecedor.

Outro exemplo: E se a inspeção fosse severa? Mantendo as demais condições, quais seriam o tamanho da amostra e os critérios de aceitação/rejeição?

Resposta: Agora consultando a **Tabela 11.2**, vemos que o tamanho da amostra é o mesmo que na inspeção normal, mas seus critérios são mais rígidos: só aceitamos o lote se houver um máximo de três peças defeituosas (com quatro ou mais defeituosas, o lote seria devolvido).

Repare que, ainda nas mesmas condições, se a inspeção fosse atenuada, o tamanho da amostra seria bem menor: somente 80 unidades. E o valor de Ac é 2. Mas, curiosamente, o valor de $Re = 5$. Ou seja, aceitamos o lote com um máximo de duas peças defeituosas, mas devolvemos se forem cinco ou mais. Mas, o que fazemos se forem três ou quatro peças defeituosas? A resposta a essa pergunta é dada por Costa, Epprecht e Carpinetti (2016, p. 284): “Se o número de peças defeituosas (ou de falhas) exceder o valor de Ac , porém for menor do que o Re , o lote deve ser aceito, mas a inspeção normal deverá ser reintroduzida nos lotes subsequentes”.

Essa é a situação que foi mostrada na **Figura 11.3**: um lote rejeitado ou “quase rejeitado” (isto é, cuja quantidade de peças defeituosas é superior ao Ac) faz cessar a condição de inspeção atenuada. A diferença é que, se a quantidade de peças ficar entre Ac e Re , o lote não chega a ser devolvido, compreende?



Saiba mais...

Importante notar que a NBR 5426 (ABNT, 1985) não apresenta diretamente o tamanho da amostra e os valores de Ac e Re a partir do tamanho do lote, como mostrado nas **Tabelas 11.1, 11.2 e 11.3**. A norma apresenta uma tabela com códigos alfabéticos (denominados códigos literais na citada norma), definidos a partir do tamanho do lote e do nível de inspeção, como mostrado na **Tabela 11.4**, e tais códigos são usados para consultar as tabelas com o tamanho da amostra e os valores de Ac e Re , como a tabela mostrada na **Figura 11.4**.

Tabela 11.4: Codificação da amostragem para diferentes níveis de inspeção

Tamanho do lote	Níveis especiais de inspeção				Níveis gerais de inspeção		
	S1	S2	S3	S4	I	II	II
2 a 8	A	A	A	A	A	A	B
9 a 15	A	A	A	A	A	B	C
16 a 25	A	A	B	B	B	C	D
26 a 50	A	B	B	C	C	D	E
51 a 90	B	B	C	C	C	E	F
91 a 150	B	B	C	D	D	F	G
151 a 280	B	C	D	E	E	G	H
281 a 500	B	C	D	E	F	H	J
501 a 1200	C	C	E	F	G	J	K
1201 a 3200	C	D	E	G	H	K	L
3201 a 10.000	C	D	F	G	J	L	M
10.001 a 35.000	C	D	F	H	K	M	N
35.001 a 150.000	D	E	G	J	L	N	P
150.001 a 500.000	D	E	G	J	M	P	Q
Acima de 500.000	D	E	H	K	N	Q	R

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p. 7), de BESTERFIELD (1990, p. 238) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 281).

Código de amostragem	Tamanho do lote em unidades	NQA																									
		0,010	0,015	0,025	0,040	0,065	0,10	0,15	0,25	0,40	0,65	1,0	1,5	2,5	4,0	6,5	10	15	25	40	65	100	150	250	400	650	1.000
A	2	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
B	3	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
C	5	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
D	8	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
E	13	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
F	20	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
G	32	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
H	50	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
J	80	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
K	125	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
L	200	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
M	315	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
N	500	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
P	800	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Q	1.250	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
R	2.000	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓

Figura 11.4: Exemplo de tabela de plano de amostragem. Uma vez identificado o código de amostragem (letra obtida a partir do tamanho do lote e do nível de inspeção), identifica-se os valores de Ac e Re para cada valor de NQA. As setas para baixo e para cima são indicativos de que se deve utilizar o primeiro plano abaixo ou acima delas.

Fonte: ABNT (1985, p. 8).



Saiba mais...

De acordo com Costa, Epprecht e Carpinetti (2016, p. 253), se nosso interesse for a quantidade de defeitos, ao invés da classificação como defeituosos ou não: “Os planos da norma NBR 5426 podem ser utilizados também nesses casos: basta fazer o NQA igual ao número de defeitos por cada 100 unidades (DCU – Defeitos por Centena de Unidades) que pode ser considerado satisfatório como média do processo”.

Inspeção retificadora

Costa, Epprecht e Carpinetti (2016, p. 244) chamam a atenção para a existência da inspeção retificadora, a qual tem características distintas da inspeção para aceitação: se na inspeção para aceitação, os lotes rejeitados

são devolvidos ao fornecedor, na inspeção retificadora “os lotes rejeitados são submetidos à inspeção 100%, e todos os itens defeituosos do lote são substituídos por itens bons”.

Usualmente, tal prática ocorre quando há receio quanto à capacidade e/ou idoneidade do fornecedor, ou seja, quanto à possibilidade de este entregar novamente lotes anteriormente rejeitados. Desta forma, a prática usual é que o lote rejeitado ($d \geq Re$) seja inspecionado 100% pelo próprio fornecedor, “idealmente na presença de um representante legal do comprador” (COSTA; EPPRECHT; CARPINETTI, 2016, p. 244), substituindo os itens defeituosos por bons.

Observe que, apesar de não ser uma prática recomendável, por ser cara, demorada e reativa, o fato é que a substituição dos itens defeituosos faz com que a quantidade total e a proporção de itens defeituosos diminuam, pois os lotes aprovados podem conter unidades defeituosas (estando, no entanto, dentro do limite aceitável de $d < Re$), ao passo que os lotes rejeitados não teriam, hipoteticamente falando, nenhuma unidade defeituosa após a substituição por itens bons.

Plano de amostragem dupla

Costa, Epprecht e Carpinetti (2016, p. 247) citam, ainda, a existência da inspeção a partir de planos de amostragem dupla, a qual “visa reduzir o número de itens do lote a inspecionar”, o que ocorre de acordo com a seguinte lógica: é coletada a primeira amostra de um lote e a quantidade de unidades defeituosas é comparada com os valores de Ac e Re tabelados. A exemplo do que ocorre na inspeção simples, caso $d \leq Ac$, o lote é aprovado, e se $d \geq Re$, o lote é devolvido. Mas, caso $d > Ac$ e $< Re$, deve ser coletada uma segunda amostra, a qual deve, também, ser inspecionada, e a quantidade de unidades defeituosas encontrada deve ser somada à quantidade encontrada na primeira amostra e tal total deve ser comparado com os valores de Ac e Re dessa nova situação, levando à decisão de aceitação do lote (se $d \leq Ac$) ou à sua devolução (caso $d \geq Re$).

O plano de amostragem dupla deve estabelecer, assim, os tamanhos das amostras (n_1 e n_2), os limites de aceitação e rejeição da primeira amostra (Ac_1 e Re_1) e da segunda (Ac_2 e Re_2), os quais são confrontados com a quantidade de peças defeituosas da primeira amostra (d_1) e com o total das duas amostras ($d_1 + d_2$), como mostrado na **Figura 11.5**.

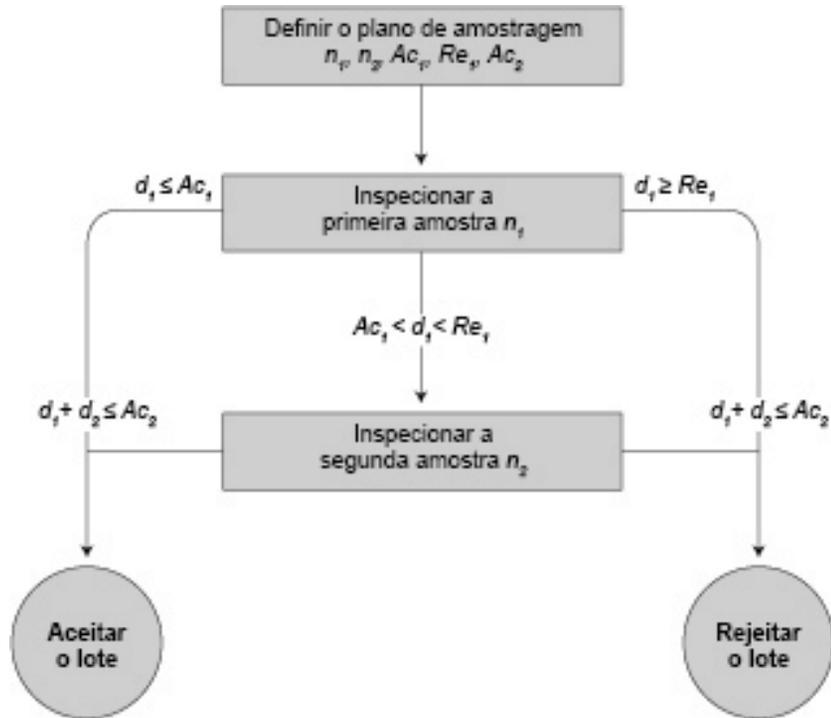


Figura 11.5: Inspeção para aceitação com amostra dupla. Se o resultado da primeira inspeção levar à aceitação ou rejeição do lote, não há a segunda inspeção. Esta só acontecerá se a quantidade de unidades defeituosas for maior que Ac_1 e menor que Re_1 , isto é, $Ac_1 < d_1 < Re_1$.

Fonte: COSTA; EPPRECHT; CARPINETTI (2016, p. 248).

As tabelas a seguir apresentam, a partir das faixas de tamanhos dos lotes, os tamanhos das amostras (primeira e segunda) e os valores limites de aceitação (Ac_1 e Ac_2) e rejeição (Re_1 e Re_2), considerando o nível geral de inspeção II e NQA de 0,10%, 0,15%, 0,25%, 1,0%, 2,5% e 10% (para outros níveis de inspeção e NQA, consulte a NBR 5426:1985).

Observe que, ao lado de cada faixa de tamanho de lote, há duas linhas que representam os valores de n , Ac e Re para a primeira e para a segunda amostra, respectivamente. Para as células em branco, é prevista a utilização da “amostragem simples correspondente” (COSTA; EPPRECHT; CARPINETTI, 2016, p. 285).

Tabela 11.5: Plano de amostragem normal dupla para nível de inspeção geral II

Tamanho do lote	Tamanho da amostra	NQA											
		0,10		0,15		0,25		1,0		2,5		10	
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re
9 a 15	2											0	2
	2											1	2
16 a 25	3											0	2
	3											1	2
26 a 50	5											0	3
	5											3	4
51 a 90	8									0	2	1	4
	8									1	2	4	5
91 a 150	13									0	2	2	5
	13									1	2	6	7
151 a 280	20							0	2	0	3	3	7
	20							1	2	3	4	8	9
281 a 500	32							0	2	1	4	5	9
	32							1	2	4	5	12	13
501 a 1.200	50							0	3	2	5	7	11
	50							3	4	6	7	18	19
1.201 a 3.200	80					0	2	1	4	3	7	11	16
	80					1	2	4	5	8	9	26	27
3.201 a 10.000	125			0	2	0	2	2	5	5	9	11	16
	125			1	2	1	2	6	7	12	13	26	27
10.001 a 35.000	200	0	2	0	2	0	3	3	7	7	11	11	16
	200	1	2	1	2	3	4	8	9	18	19	26	27
35.001 a 150.000	315	0	2	0	3	1	4	5	9	11	16	11	16
	315	1	2	3	4	4	5	12	13	26	27	26	27
150.001 a 500.000	500	0	3	1	4	2	5	7	11	11	16	11	16
	500	3	4	4	5	6	7	18	19	26	27	26	27
Acima de 500.000	800	1	4	2	5	3	7	11	16	11	16	11	16
	800	4	5	6	7	8	9	26	27	26	27	26	27

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p.11) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 285).

Tabela 11.6: Plano de amostragem severa dupla para nível de inspeção geral II

Tamanho do lote	Tamanho da amostra	NQA											
		0,10		0,15		0,25		1,0		2,5		10	
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re
9 a 15	2											0	2
	2											1	2
16 a 25	3											0	2
	3											1	2
26 a 50	5											0	2
	5											1	2
51 a 90	8									0	2	0	3
	8									1	2	3	4
91 a 150	13									0	2	1	4
	13									1	2	4	5
151 a 280	20							0	2	0	2	2	5
	20							1	2	1	2	6	7
281 a 500	32							0	2	0	3	3	7
	32							1	2	3	4	11	12
501 a 1.200	50							0	2	1	4	6	10
	50							1	2	4	5	15	16
1.201 a 3.200	80					0	2	0	3	2	5	9	14
	80					1	2	3	4	6	7	23	24
3.201 a 10.000	125			0	2	0	2	1	4	3	7	9	14
	125			1	2	1	2	4	5	11	12	23	24
10.001 a 35.000	200	0	2	0	2	0	2	2	5	6	10	9	14
	200	1	2	1	2	1	2	6	7	15	16	23	24
35.001 a 150.000	315	0	2	0	2	0	3	3	7	9	14	9	14
	315	1	2	1	2	3	4	11	12	23	24	23	24
150.001 a 500.000	500	0	2	0	3	1	4	6	10	9	14	9	14
	500	1	2	3	4	4	5	15	16	23	24	23	24
Acima de 500.000	800	1	4	0	3	1	4	2	5	9	14	9	14
	800	4	5	3	4	4	5	6	7	23	24	23	24

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p. 12) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 286).

Tabela 11.7: Plano de amostragem atenuada dupla para nível de inspeção geral II

Tamanho do lote	Tamanho da amostra	NQA											
		0,15		0,25		1,0		2,5		10		0,10	
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re
26 a 50	2											0	3
	2											0	4
51 a 90	3									0	2	0	3
	3									1	2	1	5
91 a 150	5									0	2	0	4
	5									1	2	3	6
151 a 280	8							0	2	0	3	1	5
	8							1	2	0	4	4	7
281 a 500	13							0	2	0	4	2	7
	13							1	2	1	5	6	9
501 a 1.200	20							0	3	0	4	3	8
	20							0	4	3	6	8	12
1.201 a 3.200	32					0	2	0	4	1	5	5	10
	32					1	2	1	5	4	7	12	16
3.201 a 10.000	50			0	2	0	2	0	4	2	7	5	10
	50			1	2	1	2	3	6	6	9	12	16
10.001 a 35.000	80	0	2	0	2	0	3	1	5	3	8	5	10
	80	1	2	1	2	0	4	4	7	8	12	12	16
35.001 a 150.000	125	0	2	0	3	0	4	2	7	5	10	5	10
	125	1	2	0	4	1	5	6	9	12	16	12	16
150.001 a 500.000	200	0	3	0	4	0	4	3	8	5	10	5	10
	200	0	4	1	5	3	6	8	12	12	16	12	16
Acima de 500.000	800	1	315	0	4	0	4	1	5	5	10	5	10
	800	4	315	1	5	3	6	4	7	12	16	12	16

Fonte: Adaptada da NBR 5426 (ABNT, 1985, p. 13) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 287).

Vamos a um exemplo: Supondo um lote de 6.000 peças submetido à inspeção dupla atenuada, nível II, NQA = 1%, consultamos a Tabela 11.7 e identificamos que o tamanho da primeira amostra deve ser de 50 unidades. Coletamos as unidades, garantindo que sejam unidades aleatórias e as inspecionamos. Supondo que, dentre as 50 unidades da amostra, encontremos três defeituosas, temos a situação de que $d > Ac$ ($3 > 0$) e $d < Re$ ($3 < 4$). Desta forma, não é possível aceitar o lote, nem rejeitá-lo. Devemos, assim, coletar a segunda amostra, também de tamanho 50, como você pode ver na Tabela 11.7 e a inspecionamos.

Se, ao inspecionarmos a segunda amostra, encontrarmos, por exemplo, duas unidades defeituosas, temos que $d_1 + d_2 = 3 + 2 = 5$ e tal valor deve ser comparado com Ac_2 e Re_2 (respectivamente, 3 e 6). Observe que $5 > 3$, logo não aceitamos diretamente o lote. No entanto, $5 < 6$ e, desta forma, ele não deve ser devolvido. Caímos na situação limite de que o lote deve ser aceito, porém, a inspeção atenuada deve ser suspensa para os próximos lotes recebidos, migrando, assim, para a inspeção normal.

Uma dúvida que pode surgir é: qual a melhor estratégia, inspeção simples ou dupla? Reflita um pouco sobre isso...

De acordo com Montgomery (2001), em termos estatísticos, os riscos de aceitar lotes que não deveriam ser aceitos e rejeitar lotes que deveriam ser aceitos são os mesmos em ambos os casos. No entanto, o autor aponta algumas vantagens do uso da amostragem dupla: o tamanho da amostra é menor quando aceitamos ou rejeitamos o lote na primeira amostragem (afinal, só há a segunda amostra se $d > Ac$ e $d < Re$). E, mesmo que haja a segunda amostra, pode até não ser necessário completar a inspeção desta: tome, por exemplo, a situação que estudamos há pouco: já havíamos identificado três unidades defeituosas na primeira amostra e, conseqüentemente, a segunda amostra poderia ter no máximo as duas unidades defeituosas que encontramos. Mas, vamos supor que a situação não fosse exatamente essa e que, antes de inspecionarmos todas as 50 unidades da segunda amostra, já encontrássemos três unidades defeituosas. Nesse caso, o total de $d_1 + d_2$ já alcançaria seis unidades defeituosas, o que já seria o suficiente para a decisão de devolver o lote. Não haveria, assim, razão para continuar a inspeção e ela poderia ser encerrada antes de completar as 50 peças.

Montgomery (2001) cita, ainda, o efeito psicológico sobre o fornecedor, pois a segunda amostra é percebida como uma “segunda chance” do lote. Mas, é importante destacar que a amostragem dupla é um processo mais complexo (duas amostras, dois limites de aceitação e de rejeição,

a necessidade de somar a quantidade de unidades não conformes para tomar a decisão sobre o lote após a segunda amostra, etc.), inclusive pelo fato de que o lote deve ser adequadamente armazenado, enquanto se aguarda a decisão de ser necessário coletar a segunda amostra ou não. Tudo isso torna o processo mais suscetível a erros.

Plano de amostragem múltipla

Besterfield (1990) e Montgomery (2001) apresentam o plano de amostragem múltiplo, que é uma extensão da amostragem dupla, inclusive seguindo a mesma lógica, isto é, há as tabelas que definem os tamanhos de amostra (d_1 até d_7) para inspeção comum, severa e atenuada, bem como os valores de aceitação (Ac_1 até Ac_7) e rejeição (Re_1 até Re_7) para os diversos NQAs.

Assim, coleta-se e inspeciona-se a primeira amostra e, caso o lote não seja aceito nem rejeitado ($Ac_1 < d_1 \leq Re_1$), coleta-se e inspeciona-se a segunda amostra. Se, novamente, o lote não for aceito nem rejeitado ($Ac_2 < d_1 + d_2 \leq Re_2$), coleta-se e inspeciona-se a terceira amostra, e assim sucessivamente. As tabelas correspondentes às inspeções múltiplas podem ser vistas nas páginas 14 a 19 da NBR 5426 (ABNT, 1985).

Atividade

Atende aos objetivos 1 e 2

No conteúdo desta aula, você aprendeu como determinar planos de amostragem e como avaliar os resultados da inspeção, tomando a decisão de aceitar ou rejeitar lotes. Assim, analise a seguinte situação:

Um fornecedor que já entregou 10 lotes consecutivos de inspeção normal sem ter qualquer um deles rejeitados, entrega um lote de 50.000 peças, que passam por um plano de amostragem dupla, nível II, NQA = 1%. Seis peças da primeira amostra contêm defeitos. Discorra sobre que decisões devem ser tomadas quanto ao citado lote.

Resposta comentada

Como o fornecedor já entregou 10 lotes consecutivos aceitos em inspeção normal, deve ter a inspeção comutada para atenuada na entrega desse lote. Consultando a **Tabela 11.7** (Plano de amostragem atenuada dupla para nível de inspeção geral II), observa-se que tanto a primeira quanto a segunda amostra devem ter tamanho 125.

Tamanho do lote	Tamanho da amostra	NQA												
		0,10		0,15		0,25		1,0		2,5		10		
		Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	Ac	Re	
26 a 50	2											0	3	
	2											0	4	
51 a 90	3										0	2	0	3
	3										1	2	1	5
91 a 150	5										0	2	0	4
	5										1	2	3	6
151 a 280	8							0	2	0	3	1	5	
	8							1	2	0	4	4	7	
281 a 500	13							0	2	0	4	2	7	
	13							1	2	1	5	6	9	
501 a 1.200	20							0	3	0	4	3	8	
	20							0	4	3	6	8	12	
1.201 a 3.200	32					0	2	0	4	1	5	5	10	
	32					1	2	1	5	4	7	12	16	
3.201 a 10.000	50			0	2	0	2	0	4	2	7	5	10	
	50			1	2	1	2	3	6	6	9	12	16	
10.001 a 35.000	80	0	2	0	2	0	3	1	5	3	8	5	10	
	80	1	2	1	2	0	4	4	7	8	12	12	16	
35.001 a 150.000	125	0	2	0	3	0	4	2	7	5	10	5	10	
	125	1	2	0	4	1	5	6	9	12	16	12	16	
150.001 a 500.000	200	0	3	0	4	0	4	3	8	5	10	5	10	
	200	0	4	1	5	3	6	8	12	12	16	12	16	
Acima de 500.000	800	1	315	0	4	0	4	1	5	5	10	5	10	
	800	4	315	1	5	3	6	4	7	12	16	12	16	

Reprodução da Tabela 11.7. Adaptada da NBR 5426 (ABNT, 1985, p. 13) e de COSTA; EPPRECHT; CARPINETTI (2016, p. 287).

Podemos observar, também, que os valores de Ac e Re para a primeira amostra são, respectivamente, 2 e 7. Como foram encontradas seis unidades defeituosas ($2 < 6 < 7$), deve ser coletada e inspecionada uma segunda amostra do lote, com 125 unidades.

Caso nenhuma unidade defeituosa seja encontrada na segunda amostra, o lote deve ser aceito ($6 + 0 = 6 = Ac_2$). Por outro lado, se forem encontradas um ou duas unidades defeituosas, o que faria com que $d_1 + d_2$ totalizasse sete ou oito (inferior, portanto, ao $Re_2 = 9$), o lote também seria aceito, porém a inspeção a ser aplicada a partir do próximo lote deixaria de ser atenuada, passando a normal.

No entanto, se ao longo do processo de inspeção da segunda amostra fossem encontradas três unidades defeituosas, o processo de inspeção poderia ser paralisado, visto que já se alcançaria um total de $d_1 + d_2 = 9$, o lote deveria ser devolvido e, também nesse caso, o próximo lote deveria passar pela inspeção normal e não mais ser atenuada.

Conclusão

Ainda que a inspeção de recebimento tenha um viés reativo, isto é, são feitas análises posteriores à produção e ao fornecimento dos lotes, os quais são inspecionados e avaliados quanto a se devem ser aceitos ou devolvidos, a utilização das técnicas de inspeção por amostragem nela utilizadas atenuam a demora e os gastos envolvidos em inspeções 100%.

Podemos considerar, assim, a inspeção por amostragem como um meio termo entre a inspeção 100%, um sistema antiquado com uma série de deficiências, e o controle estatístico de processos, que permite se antecipar à ocorrência dos problemas, agindo preventiva e proativamente.

Resumo

Um processo ainda hoje utilizado é o da inspeção de recebimento, que consiste em o fornecedor entregar os lotes produzidos, mas estes só serem aceitos depois de inspecionados: caso não atendam a parâmetros previamente estabelecidos, em termos de quantidade máxima de peças defeituosas, os lotes são devolvidos (ou, em condições específicas, há a denominada inspeção retificadora, em que o lote é inspecionado 100% e as peças defeituosas são substituídas por peças “boas”).

Importante destacar que, por lidar com probabilidades (por inspecionar amostras, e não o lote inteiro), há riscos envolvidos:

Risco α : o chamado risco do produtor, referente à probabilidade de rejeição de um lote de um processo de “boa qualidade”, isto é, em que a proporção de peças defeituosas é igual ou inferior ao esperado em bases estatísticas (lembre-se de que, se trabalhamos com probabilidades, não podemos ter 100% de certeza sobre a qualidade);

Risco β : o denominado risco do consumidor, que diz respeito à aceitação de um lote de um processo cuja proporção de itens defeituosos seja superior ao esperado.

Tais processos de inspeção são norteados por normas específicas. Dentre elas, a ABNT NBR 5426:1985, a qual estabelece planos de amostragem e procedimentos para inspeção por atributos.

Em tal norma, uma vez estabelecido o tipo de inspeção (normal, severa ou atenuada) e o nível de inspeção (I, II, III, S1, S2, S3 e S4), bem como o NQA (nível de qualidade aceitável) e se será aplicada a inspeção simples, dupla ou múltipla, é possível, a partir do tamanho do lote, estabelecer os critérios de aceitação e rejeição deste. Tais critérios, constantes em tabelas diversas, indicam a quantidade máxima aceitável de unidades defeituosas na amostra de um lote (Ac) e a quantidade a partir da qual o lote deve ser rejeitado (Re), bem como regras para migrar entre as inspeções normal, severa ou atenuada.

Leituras recomendadas

PEREIRA NETO, Antônio Luiz; CAMPOS, Marianna Cruz; SILVEIRA, Roseane Rodrigues; ALMEIDA, Mariana Rodrigues. Controle estatístico da qualidade: planejamento de amostragem para diminuição de erros de inspeção. In: XXXIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Salvador, BA, Brasil, 08 a 11 de outubro de 2013. *Anais...* Disponível em: http://www.abepro.org.br/biblioteca/enegep2013_TN_STO_178_015_22923.pdf. Acesso em: 11 jun. 2019.

Informação sobre o próxima aula

Na próxima aula, continuaremos os estudos da inspeção por amostragem, com foco na inspeção por variáveis.

Referências

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. *ABNT NBR 5426:1985* – Planos de amostragem e procedimentos na inspeção por atributos. Rio de Janeiro: ABNT, 1985.

BESTERFIELD, Dale H. *Quality Control*. 3. ed. Englewood Cliffs: Prentice-Hall, 1990.

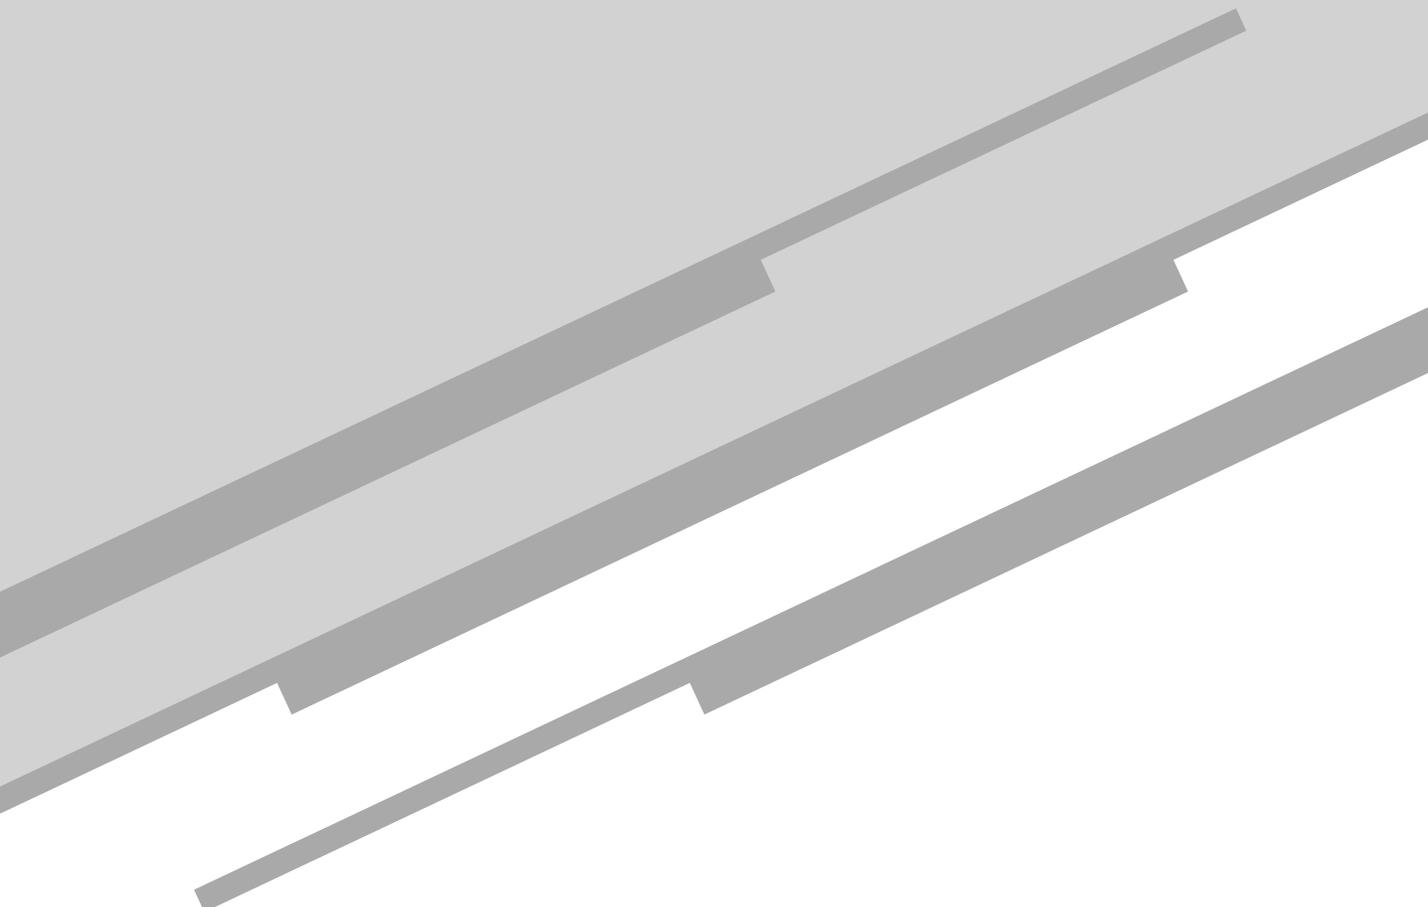
COSTA, Antônio Fernando Branco; EPPRECHT, Eugenio Kahn; CARPINETTI, Luiz César Ribeiro. *Controle estatístico de qualidade*. 2. ed. São Paulo: Atlas, 2016.

DOANE, David P.; SEWARD, Lori E. *Estatística aplicada à Administração e Economia*. Porto Alegre: AMGH, 2014.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. 4. ed. New York: John Wiley & Sons, 2001.

Aula 12

Inspeção da qualidade (continuação)



Henrique Martins Rocha

Metas

Relembrar algumas distribuições de probabilidade usadas em uma inspeção de qualidade; apresentar planos de amostragem de aceitação lote a lote para atributos e mostrar a inspeção de retificação.

Objetivos

Esperamos que, ao final desta aula, você seja capaz de:

1. dependendo do número de itens defeituosos na amostra, aceitar ou rejeitar o lote;
2. determinar o plano de amostragem que mais se adequa ao problema.

Pré-requisitos

Funções estatísticas e distribuição normal, média e desvio-padrão; causas comuns e causas especiais; gráficos de controle e capacidade de processos, conteúdos estudados nas aulas anteriores.

Introdução

A utilização da inspeção por amostragem não se limita à inspeção e avaliação por atributos. A exemplo do que você estudou nos gráficos de controle, podemos trabalhar com variáveis ou atributos.

A inspeção de recebimento por amostragem para variáveis ocorre quando temos a preocupação sobre características de qualidade específicas nos lotes de peças e produtos recebidos dos fornecedores, ao invés de somente identificarmos se há ou não produtos defeituosos. Assim, avaliamos estatisticamente dimensões específicas e fazemos inferências sobre a qualidade do lote recebido e tomamos decisões sobre os lotes recebidos: aceitar ou devolver.

É isso que você estudará aqui: aprenderá sobre os procedimentos para tais inspeções e os critérios de aceitação e rejeição dos lotes. Bons estudos!

Como você aprendeu na Aula 11, ainda que a evolução da qualidade tenha levado ao uso de ferramentas de detecção de problemas, de forma a podermos nos antecipar a estes e agir preventivamente (como no caso das cartas de controle), a inspeção de recebimento ainda é utilizada em situações específicas, como, por exemplo, quando há um novo produto ou processo – ou um novo fornecedor –, e não houve ainda a qualificação dos processos produtivos.

Em situações como estas, a inspeção por amostragem é uma alternativa superior à inspeção 100%, sendo mais rápida, barata e confiável. Mas uma preocupação que pode existir é a de se utilizar a inspeção por amostragem não somente para monitorar peças “boas” ou “não conformes” e tomar decisões a partir daí, isto é, aceitar ou rejeitar lotes de fornecedores com base na quantidade ou proporção de peças defeituosas. Em peças com as quais temos uma preocupação maior, devido à funcionalidade, podemos estar interessados em avaliar medidas específicas, ou seja, a comparação de seu valor médio e a dispersão com os limites de especificação.

Ou seja, exatamente o que você estudou nos gráficos de controle por variáveis, nas Aulas 6 a 9, e na Aula 10, sobre a capacidade de processos. Mas como analisar isso em lotes que recebemos dos fornecedores? Afinal, mesmo medindo as peças, não há como segregarmos as amostras e analisarmos estatisticamente as variações que eventualmente ocorrem nos processos (de forma a identificar a ocorrência de causas especiais). Ou seja, como fazer a inspeção de recebimento por amostragem em variáveis contínuas?

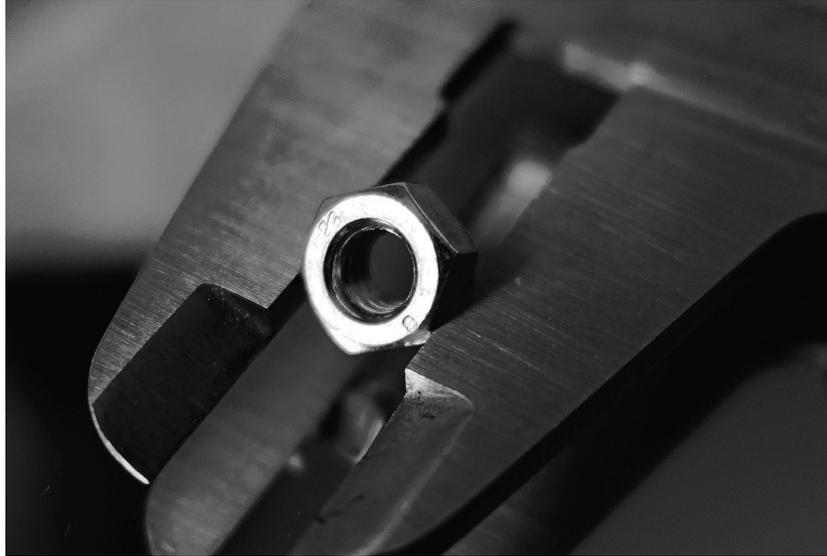


Figura 12.1: Medição de peças. Trata-se de um processo usual e necessário quando queremos monitorar o processo produtivo, extraindo amostras, medindo-as e criando os gráficos de controle para avaliar a possibilidade de existência de causas especiais que interfiram no processo. No entanto, quando as peças são recebidas do fornecedor, não há mais como monitorar o processo. Precisamos, então, avaliar por amostragem o lote recebido e tomar decisões sobre este, isto é, aceitá-lo ou rejeitá-lo, com base nas medições feitas.

Fonte: <https://pixabay.com/photos/measure-calliper-tool-accuracy-2090113/>

Obviamente, a alternativa da inspeção 100% seria uma possibilidade. Mas, isso implicaria custos maiores, além de consumir um tempo, na maioria das vezes, proibitivo (COSTA; EPPRECHT; CARPINETTI, 2016). Mas como deve ser a amostragem nesses casos? Qual o tamanho da amostra? Quais os critérios de aceitação ou de rejeição de lotes? Veremos como isso é feito.

Inspeção para aceitação por variáveis

De acordo com Besterfield (1990), a inspeção por amostragem por variáveis é baseada na média e no desvio-padrão das amostras e, também, no tipo de distribuição de frequência, podendo ser utilizada para inspeção de (ABNT, 1985a, p. 1):

1. produtos terminados;
2. componente e matéria-prima;
3. operações;
4. materiais em processamento;

5. materiais estocados e
6. operações de manutenção.

É importante destacar que, a exemplo do que você estudou na Aula 11 sobre inspeção por atributos, a inspeção por variáveis e as decisões tomadas pelos critérios estabelecidos (aceitar ou rejeitar os lotes) trazem riscos, sejam para o produtor (risco α), sejam para o consumidor (risco β) (COSTA; EPPRECHT; CARPINETTI, 2016).

Mas essa não é a única semelhança entre a inspeção de recebimento por amostragem de variáveis e a amostragem por atributos (que você estudou na Aula 11): também os complexos cálculos estatísticos são substituídos por tabelas de variáveis, as quais definem os tamanhos de amostra e critérios de aceitação dos lotes por meio de normas específicas, em especial as seguintes normas da Associação Brasileira de Normas Técnicas (ABNT):

- ABNT NBR 5429: 1985 – Planos de amostragem e procedimentos na inspeção por variáveis: Esta norma estabelece planos de amostragem e procedimentos para inspeção por variáveis;
- ABNT NBR 5430: 1985 – Guia de utilização da norma ABNT NBR 5429 – Planos de amostragem e procedimentos na inspeção por variáveis: Esta norma tem por finalidade fornecer instruções detalhadas, com exemplos ilustrativos, para aplicação e administração dos procedimentos de amostragem por variáveis estabelecidos na ABNT NBR 5429.



A ABNT é uma entidade privada e sem fins lucrativos, responsável pela elaboração das Normas Brasileiras (ABNT NBR), elaboradas por seus Comitês Brasileiros (ABNT/CB), Organismos de Normalização Setorial (ABNT/ONS) e Comissões de Estudo Especiais (ABNT/CEE).

A ABNT atua também na avaliação da conformidade e dispõe de programas para certificação de produtos, sistemas e rotulagem ambiental. Esta atividade está fundamentada em guias e princípios

técnicos internacionalmente aceitos e alicerçada em uma estrutura técnica e de auditores multidisciplinares, garantindo credibilidade, ética e reconhecimento dos serviços prestados.

Fonte: ABNT, 2014.

Cabe destacar que, por sua própria natureza, a inspeção por variáveis não prevê a existência de amostragem dupla ou múltipla: a amostragem é sempre simples. Além disso, deve ser garantido que os lotes sejam homogêneos e que a amostra seja coletada de forma randômica, para garantir que ela seja representativa do lote (vide Aula 11).

Vantagens e desvantagens da inspeção por amostragem por variáveis

De acordo com Besterfield (1990) e Montgomery (2001), temos as seguintes vantagens da inspeção por amostragem por variáveis, quando comparada com a inspeção por atributos:

Vantagens

- O tamanho das amostras, para as mesmas condições, é menor.
- Ainda que a complexidade e o custo unitário de inspeção sejam maiores do que no caso de atributos, é comum que o custo total seja menor, devido à redução do tamanho da amostra.
- As medições da amostra proveem mais informações sobre o processo produtivo do que a inspeção por atributos.
- A melhor compreensão sobre o processo produtivo permite melhor base para ações de melhoria da qualidade.
- Para inspeções com NQA (nível de qualidade aceitável) muito baixo, o tamanho da amostra recomendado é muito grande, tornando-se mais atrativo proceder com a inspeção por variáveis.

Desvantagens

- Deve haver um plano de amostragem para cada característica de qualidade das peças inspecionadas (ao contrário da inspeção por atributos, em que se avalia se as peças simplesmente são defeituosas ou não);
- Como o método avalia valores médios de medidas e sua dispersão, pode haver rejeição de lotes mesmo que a amostra não apresente peças defeituosas, o que pode gerar certo desconforto entre fornecedor e cliente.
- Amostragem por variáveis usualmente envolve mais custos administrativos, documental e de equipamentos.
- A distribuição da população deve ser conhecida ou estimada.

Por exemplo, um lote de 1.000 peças exigiria, considerando uma amostragem normal por atributos nível II, uma amostra de 80 peças (vide Aula 11), ao passo que, se por variáveis, considerando as mesmas características, o tamanho da amostra seria de somente 40 peças. Tal diferença é ainda mais acentuada em grandes lotes: acima de 500.000 peças, os tamanhos de amostra, nas mesmas condições, seriam, respectivamente, de 1.250 e 250 peças, ou seja, cinco vezes menor!

Isso significa que SEMPRE será mais fácil a inspeção por variáveis? Na realidade, não: dependendo da natureza das peças a serem inspecionadas, pode ser necessário inspecionar diversas características da mesma peça, o que tornaria o processo bem mais complexo.

Pense, por exemplo, em um simples pino: suas características dimensionais são o seu diâmetro e comprimento. Já quanto às características geométricas, podemos listar retitude, circularidade, cilindridade, etc. (ABNT, 1997). Podemos, ainda, estar interessados na rugosidade da superfície, dureza do material, etc.

Por outro lado, uma inspeção por atributos se limitaria a avaliar se as peças contêm defeitos ou não (e, eventualmente, contabilizar a quantidade de defeitos, dependendo se estamos preocupados em monitorar defeitos ou unidades defeituosas, como você viu nas Aulas 8 e 9). E ainda poderíamos expandir a inspeção por atributos para avaliar danos diversos, marcas e arranhões, oxidação, etc., sem que isso aumentasse significativamente a complexidade do processo.

Desta forma, ao compararmos o volume de informações, a dificuldade nos cálculos e o volume de registros, a inspeção por variáveis pode, apesar da redução no tamanho das amostras, ser bem mais complexa do que a por atributos.

Plano de amostragem

A NBR 5429: 1985 estabelece planos de amostragem “conforme o conhecimento ou não da variabilidade do processo” (ABNT, 1985b, p. 4), ou seja, variabilidade conhecida ou variabilidade desconhecida. No caso da variabilidade desconhecida, os métodos para estimar o parâmetro de dispersão do lote podem ser o da amplitude média da amostra ou do desvio-padrão estimativo do lote.

Montgomery (2001) alerta para os riscos de se desconhecer a distribuição nas amostras por variáveis. O autor cita que, por exemplo, se assumirmos uma distribuição normal, mas tal premissa não for verdadeira, as análises feitas podem ser inadequadas, levando a decisões erradas sobre a aceitação do lote. Por isso, os testes de normalidade (vide Aula 7) são importantes quando trabalhamos com inspeção por variáveis.

De acordo com a norma NBR 5430: 1985 (ABNT, 1985b, p. 2): “Geralmente usa-se o plano de amostragem para variabilidade desconhecida, método do desvio-padrão. Quando especificado no contrato ou outro documento, pode ser utilizado o método da amplitude”. E ainda: “A variabilidade conhecida só deve ser utilizada quando houve certeza do conhecimento da variabilidade do processo do fornecedor, devendo antes ser consultado o departamento técnico competente sobre a possibilidade de sua utilização” (idem).

O desenvolvimento do plano de amostragem inicia com a definição do nível de inspeção. Da mesma forma que na inspeção por atributos, que você estudou na Aula 11, a norma NBR 5429: 1985 (ABNT, 1985a) também tem três níveis gerais e quatro níveis especiais de inspeção (respectivamente, I, II, III, S1, S2, S3 e S4). E, corroborando com Costa, Epprecht e Carpinetti (2016), a norma NBR 5430: 1985 (ABNT, 1985b, p. 2) recomenda o uso do nível II: “No início do contrato ou produção é aconselhável usar o nível II. Podem ser usados outros níveis de inspeção, se o histórico de qualidade ou se as dificuldades e custo de controle assim o indicam”.

A partir do tamanho do lote e do nível de inspeção, identifica-se o código literal (vide Aula 11), mostrado na **Tabela 12.2** (somente para nível II; para outros níveis de inspeção, consulte a NBR 5429: 1985).

Tabela 12.2: Código literal para plano de amostragem para nível de inspeção geral II

Tamanho do lote	Codificação	Tamanho da amostra
2 a 8	B	3
9 a 15	B	3
16 a 25	C	4
26 a 50	D	6
51 a 90	E	9
91 a 150	F	13
151 a 280	G	18
281 a 500	H	25
501 a 1.200	J	40
1.201 a 3.200	K	60
3.201 a 10.000	L	95
10.001 a 35.000	M	120
35.001 a 150.000	N	150
150.001 a 500.000	P	200
Acima de 500.000	Q	250

Fonte: Adaptado de NBR 5429: 1985 (ABNT, 1985a, p. 7).

Em seguida, estabelece-se a severidade da inspeção: o padrão é exatamente o mesmo da norma NBR 5426: 1985, isto é, selecionar entre inspeção normal, severa ou atenuada. Como consta na NBR 5430: 1985 (ABNT, 1985b, p. 2): “No início de contrato ou produção, utiliza-se inspeção em regime normal” e isso pode ser modificado de acordo com o histórico do fornecedor, basicamente sob a mesma lógica apresentada na Aula 11, descrita por Costa, Epprecht e Carpinetti (2016) e replicada na **Figura 12.3**.

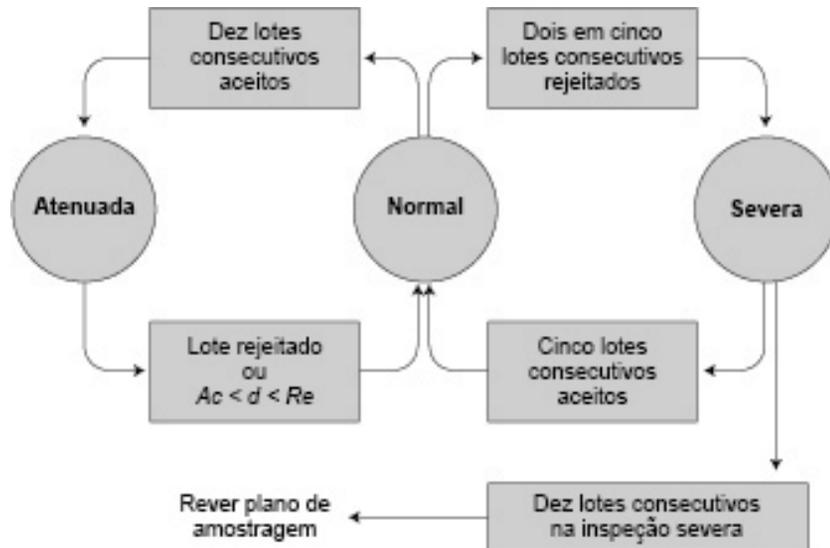


Figura 12.3: Regras gerais para comutação entre os modos de inspeção. Repare que o desempenho do fornecedor, ou seja, da aceitação ou rejeição de seus lotes, vai fazer com que a inspeção aplicada nos lotes recebidos possa ser modificada.

Fonte: COSTA, EPPRECHT E CARPINETTI (2016, p. 253).

O próximo passo é determinar o tamanho da amostra e a porcentagem defeituosa máxima admissível (M). Para tanto, a **Tabela 12.2** apresenta, também, os tamanhos de amostra (a partir do tamanho do lote, enquanto na tabela original da NBR 5429: 1985, tal informação é obtida a partir do código literal, em uma tabela separada), para inspeção normal a severa. E a **Tabela 12.4** apresenta as porcentagens defeituosas admissíveis, considerando o nível geral de inspeção II e NQA de 0,10%, 0,15%, 0,25%, 1,0%, 2,5% e 10% (para outros níveis de inspeção e NQA, consulte a NBR 5429: 1985).

Tabela 12.4: Plano de amostragem – variabilidade desconhecida – normal, nível de inspeção geral II

NQA	Tamanho da amostra													
	3	4	6	9	13	18	25	40	60	95	120	150	200	250
0,10	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,22	0,22	0,22	0,22
0,15	0,47	0,47	0,47	0,47	0,47	0,47	0,47	0,47	0,47	0,31	0,31	0,33	0,33	0,33
0,25	0,69	0,69	0,69	0,69	0,69	0,69	0,69	0,69	0,57	0,57	0,57	0,59	0,59	0,59
1,0	3,09	3,09	3,09	3,09	3,09	2,77	2,77	2,82	2,69	2,80	2,37	2,08	1,79	1,70
2,5	8,00	8,00	8,00	6,94	6,94	8,26	6,81	6,81	5,90	5,31	4,58	4,32	4,32	4,32
10	33,33	33,33	32,01	28,52	27,76	24,10	21,89	18,70	17,38	17,38	17,38	17,38	17,38	17,38

Fonte: Adaptado de NBR 5429: 1985 (ABNT, 1985a, p. 8).

A **Tabela 12.5** apresenta a porcentagem defeituosa máxima admissível para inspeção severa. Para a inspeção atenuada, consulte a NBR 5429: 1985. Lá, a tabela apresenta valores reduzidos para o tamanho das amostras, além de mostrar as porcentagens admissíveis indicadas com *Ac* e *Re* (respectivamente aceitar e rejeitar, como você aprendeu na Aula 11). “Se a porcentagem defeituosa estimada exceder o valor de *Ac*, porém se for menor que *Re*, o lote será aceito, mas a inspeção normal deverá ser reintroduzida nos lotes subsequentes” (ABNT, 1985a, p. 10).

Tabela 12.5: Plano de amostragem – variabilidade desconhecida – severa, nível de inspeção geral II

NQA	Tamanho da amostra													
	3	4	6	9	13	18	25	40	60	95	120	150	200	250
0,10	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,14	0,14	0,14	0,14
0,15	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,22	0,22	0,22	0,22	0,22
0,25	0,54	0,54	0,54	0,54	0,54	0,54	0,54	0,54	0,31	0,31	0,31	0,33	0,33	0,33
1,0	1,84	1,84	1,84	1,84	1,84	1,68	1,68	1,68	1,47	1,59	1,59	1,62	1,54	1,54
2,5	5,60	5,60	5,60	4,48	4,48	4,48	4,94	4,29	4,29	4,39	3,94	3,97	3,97	3,97
10	20,30	20,30	20,30	20,22	18,32	17,67	16,12	15,63	14,91	14,91	14,91	14,91	14,91	14,91

Fonte: Adaptado de NBR 5429: 1985 (ABNT, 1985a, p. 9).

Uma vez estabelecido o plano de amostragem, podemos coletar a amostra, medir as peças a analisar os resultados para decidir se o lote deve ser aceito ou não. Como isso é feito?

Vamos tomar como exemplo um lote de 40 produtos (sacas de cereais, no caso) recebido e que desejamos avaliar pelo nível de inspeção geral II, inspeção normal. A medida a ser analisada é de 182 Kg, com uma tolerância superior de +28,5 Kg e uma tolerância inferior de -2,4 Kg.

Como você pode observar na **Tabela 12.2**, a amostra deve ter tamanho 6. Assim, coletamos aleatoriamente seis produtos e os medimos: os resultados são mostrados a seguir.

Amostra	Valor
1	197
2	188
3	184
4	205
5	189
6	201

Com base nas medidas da amostra, o lote deve ser aceito ou rejeitado? Bem, primeiramente, precisamos estabelecer o NQA, ou seja, o grau de confiança que desejamos ter para tomar a decisão sobre o lote.

Uma peculiaridade sobre a amostragem por variáveis é que podemos estabelecer NQAs distintos para o limite superior e para o limite inferior. Por exemplo, como o produto que estamos analisando são sacas de cereais, pode ser que haja um rigor maior no limite inferior (por exemplo, devido a possíveis reclamações pela saca estar “abaixo do peso anunciado”) do que no limite superior (visto que dificilmente haveria reclamação por receber “mais do que o anunciado”). Assim, digamos que queremos trabalhar com um NQA de 1% para o limite inferior e de 10% para o limite superior.

Consultamos, então, a **Tabela 12.4** e encontramos os valores de 3,09% e 32,01% como proporção defeituosa máxima admissível para, respectivamente, os limites inferior (Mi) e superior (Ms), como você pode ver no extrato da citada tabela a seguir.

NQA	Tamanho da amostra					
	3	4	6	9	13	18
0,10	0,24	0,24	0,24	0,24	0,24	0,24
0,15	0,47	0,47	0,47	0,47	0,47	0,47
0,25	0,69	0,69	0,69	0,69	0,69	0,69
1,0	3,09	3,09	3,09	3,09	3,09	2,77
2,5	8,00	8,00	8,00	6,94	6,94	8,26
10	33,33	33,33	32,01	28,52	27,76	24,10

Fonte: Adaptado de NBR 5429: 1985 (ABNT, 1985a, p. 8).

Mas que valores precisamos comparar com tais limites? Precisamos calcular a porcentagem de unidades defeituosas (p), para verificar se estão dentro dos limites, ou seja, se estão abaixo das porcentagens máximas admissíveis (M). Para tanto, precisamos calcular o afastamento da média da amostra para os limites de especificação, isto é, o afastamento da média para o limite superior da especificação (LSE) e para o limite inferior da especificação (LIE) e tais afastamentos devem ser dados em quantidades de desvios-padrões, que são chamados “índices de qualidade”. Temos, assim, o índice de qualidade superior (Q_s) e o índice de qualidade inferior (Q_i), que são calculados da seguinte forma:

$$Q_s = \frac{LSE - \bar{x}}{s} \quad \text{e} \quad Q_i = \frac{\bar{x} - LIE}{s}$$

Calculamos, então :

$$\bar{x} = \frac{197 + 188 + 184 + 205 + 189 + 201}{6} = 194$$

Podemos, também, calcular s :

$$s = \sqrt{\frac{(197 - 194)^2 + (188 - 194)^2 + (184 - 194)^2 + (205 - 194)^2 + (189 - 194)^2 + (201 - 194)^2}{6 - 1}} = 8,246$$

Os valores superior e inferior da especificação podem ser calculados:

$$LSE = 182 + 28,5 = 210,5 \text{ Kg; e}$$

$$LIE = 182 - 2,4 = 179,6 \text{ Kg.}$$

Desta forma, os valores de Q_s e Q_i são:

$$Q_s = \frac{210,5 - 194}{8,246} = 2,00 \quad \text{e} \quad Q_i = \frac{194 - 179,6}{8,246} = 1,75$$



Atenção: de acordo com a NBR 5429:1985 (ABNT, 1985a, p. 5), “se um dos índices de qualidade (Q_s ou Q_i) ou ambos forem negativos, o lote deverá ser rejeitado”. Ou seja, não haverá sequer continuidade da análise.

A estimativa de porcentagem defeituosa é obtida, então, pela consulta na Tabela 12.6, apresentada a seguir. As porcentagens (p) podem ser identificadas consultando os valores calculados de Q_s e Q_i para a amostra de tamanho 6.

Tabela 12.6: Estimação de porcentagem defeituosa do lote

Qi & Qs	Tamanho da amostra									
	3	4	6	9	13	18	25	40-60	95-120	≥150
0,00	50,00	50,00	50,00	50,00	50,00	50,00	50,00	50,00	50,00	50,00
0,10	47,24	46,67	36,33	46,20	46,13	46,09	46,06	46,03	46,03	46,02
0,20	44,46	43,33	42,68	42,43	42,29	42,21	42,16	42,11	42,09	42,06
0,30	41,43	40,00	39,06	38,71	38,51	38,40	38,33	38,27	38,23	38,22
0,40	38,74	36,67	35,50	35,06	34,82	34,69	34,61	34,53	34,49	34,47
0,50	35,75	33,33	32,01	31,52	31,25	31,10	31,02	30,93	30,88	30,87
0,60	32,61	30,00	28,60	28,09	27,82	27,67	27,59	27,50	27,46	27,44
0,70	29,27	26,67	25,30	24,81	24,55	24,41	24,34	24,26	24,22	24,21
0,80	25,64	23,33	22,12	21,68	21,47	21,36	21,29	21,24	21,21	21,20
0,90	21,55	20,00	19,08	18,76	18,59	18,52	18,47	18,43	18,42	18,41
1,00	16,67	16,67	16,19	16,02	15,93	15,90	15,88	15,87	15,87	15,87
1,25	0,00	8,33	9,79	10,14	10,28	10,41	10,43	10,50	10,53	10,55
1,50	0,00	0,00	4,68	5,63	6,03	6,28	6,40	6,55	6,63	6,65
1,75	0,00	0,00	1,64	2,62	3,16	3,49	3,65	3,84	3,94	3,97
2,00	0,00	0,00	0,03	0,87	1,39	1,73	1,90	2,09	2,20	2,23
2,50	0,00	0,00	0,00	0,02	0,11	0,28	0,37	0,48	0,57	0,59
3,00	0,00	0,00	0,00	0,00	0,00	0,02	0,04	0,08	0,11	0,12
3,50	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,02	0,02

Fonte: adaptado de NBR 5429: 1985 (ABNT, 1985a, p. 29-35).

Desta forma, encontramos $pi = 1,64\%$ (para Qi) e $ps = 0,03\%$ (para Qs), como você pode ver, a seguir, na **Tabela 12.7**, que é um extrato da **Tabela 12.6**.

Tabela 12.7: Extrato da Tabela 12.6

Qi & Qs	Tamanho da amostra				
	3	4	6	...	≥150
0,00	50,00	50,00	50,00	...	50,00
0,10	47,24	46,67	36,33	...	46,02
...
1,50	0,00	0,00	4,68	...	6,65
1,75	0,00	0,00	1,64	...	3,97
2,00	0,00	0,00	0,03	...	2,23
...
3,50	0,00	0,00	0,00	...	0,02

Obs: para valores de Qi e Qs não encontrados na **Tabela 12.6**, consulte a norma NBR 5429: 1985.

Comparamos, então, pi com Mi e ps com Ms . Como pi e ps são as estimativas de porcentagem defeituosa do lote (para, respectivamente, o limite inferior e superior), seus valores deverão ser iguais ou menores que Mi e Ms , que são as porcentagens defeituosas máximas admissíveis, para que o lote possa ser aceito.

Temos, então, no nosso exemplo:

$$pi = 1,64\%$$

$$ps = 0,03\%$$

$$Mi = 3,09\%$$

$$Ms = 32,01\%$$

Desta forma, $pi \leq Mi$ ($1,64\% < 3,09\%$) e $ps \leq Ms$ ($0,03\% < 32,01\%$). Mas, essa não é a única verificação que precisamos fazer para aceitar o lote: de acordo com a NBR 5429: 1985 (ABNT, 1985a), é necessário, também, verificar se o somatório das estimativas bilaterais (ou seja, inferior e superior) não supera a maior porcentagem defeituosa admissível.

Assim, como $M_i = 3,09\%$ e $M_s = 32,01\%$, precisamos, no nosso exemplo, verificar se $(p_i + p_s) \leq M_s$. Ou seja, $1,64 + 0,03 = 1,67\%$, que é menor que $32,01\%$ e, desta forma, o lote deveria ser aceito.

Parece complicado? Bem, há muitos passos a serem seguidos e muitas informações a serem coletadas e comparadas. Vamos colocar o passo a passo em forma de fluxo para revermos o que fizemos para avaliar o lote de nosso exemplo e você perceberá que não é tão complicado assim.

Veja a **Figura 12.7** e vamos discuti-la.

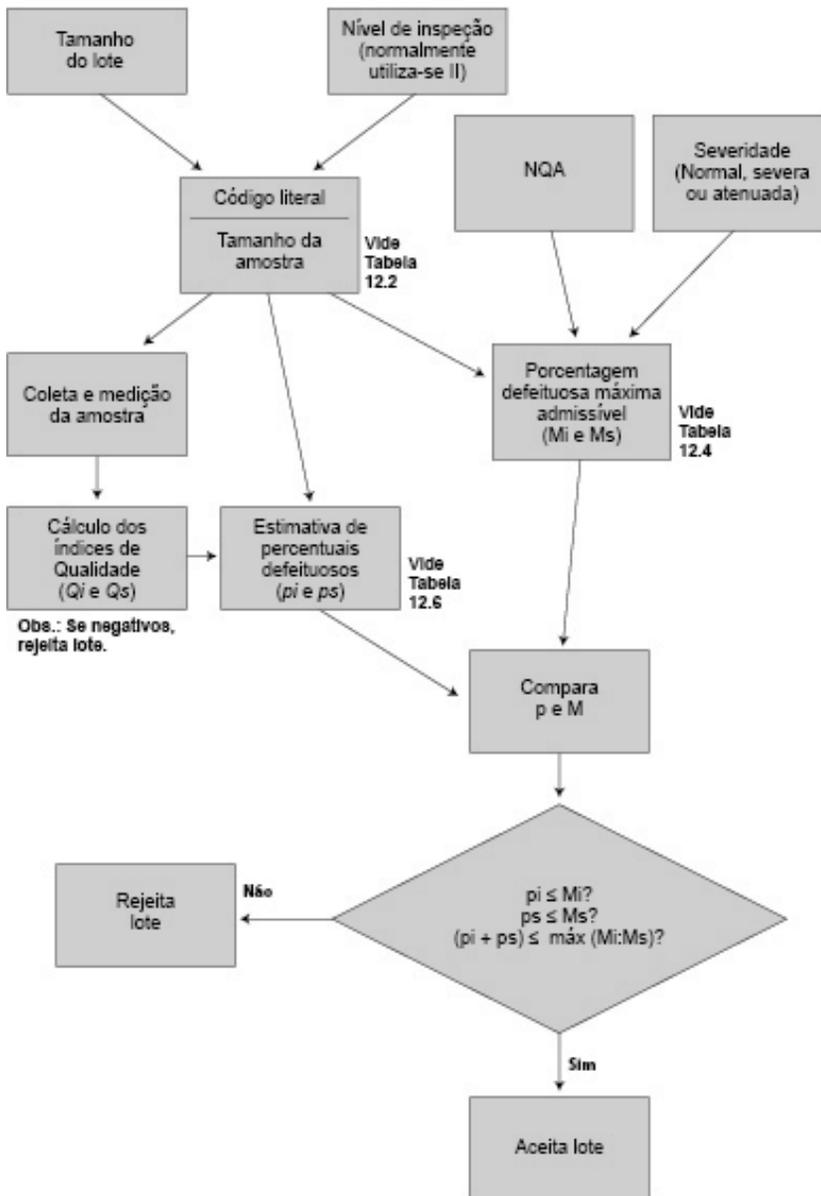


Figura 12.7: Passo a passo para amostragem e inspeção por amostragem por variáveis. Coletamos e medimos a amostra, estimando as porcentagens defeituosas. Tais porcentagens são, então, comparadas com as porcentagens máximas admissíveis: se abaixo de tais limites, o lote deve ser aceito. Caso contrário, rejeitado.

Importante destacar que, eventualmente, pode ser que a inspeção tenha foco somente no limite superior ou no limite inferior do produto fornecido. Por exemplo, uma montadora de automóveis pode estar preocupada em verificar somente o limite inferior das embalagens de tinta recebidas do fornecedor, para garantir que não esteja recebendo menos do que o previsto. Mas, por outro lado, pode estar preocupada com o limite superior do diâmetro de um pino, que poderia causar problemas na montagem devido à interferência dimensional com outra peça.

Nesses casos de limites de especificação unilateral, a sequência é basicamente a mesma que dos limites bilaterais, analisando-se, no entanto, somente o “lado” da especificação de interesse. Ou seja, deve-se comparar somente p_i com M_i , ou p_s com M_s , decidindo sobre a aceitação ou não do lote somente com base em tal parâmetro.

Nesse caso, obviamente, a comparação de $(p_i + p_s)$ com o maior valor de M , perde o sentido, não devendo ser efetuada. A propósito, de acordo com a norma NBR 5429: 1985 (ABNT, 1985a), a citada comparação só deve ser feita quando os valores de NQA forem diferentes para os limites inferior e superior. Se o valor de NQA for o mesmo, haverá somente um valor de M (isto é, não será diferenciado como M_i ou M_s) e, nesse caso, as comparações devem ser somente entre p_i e M e p_s e M , não havendo na norma qualquer recomendação quanto a $(p_i + p_s)$.

Também é importante destacar que a NBR 5429: 1985 (ABNT, 1985a) estabelece processos, também, para variabilidade desconhecida pelo método da amplitude e para variabilidade conhecida. Caso tenha interesse em conhecer tais métodos, consulte a citada norma.

Atividade

Atende aos objetivos 1 e 2

No conteúdo desta aula, você aprendeu como determinar planos de amostragem por variáveis e como avaliar os resultados da inspeção, tomando a decisão de aceitar ou rejeitar lotes. Assim, analise a seguinte situação:

Um fornecedor que já entregou nove lotes consecutivos de inspeção normal do produto X, sem ter qualquer um deles rejeitados, entrega um lote de 50 peças, cuja característica de qualidade inspecionada é a

dimensão de sua face de trabalho, que tem como especificação o valor de $195^{+14,3}_{-16,9}$ (medidas em milímetros). O plano de amostragem é de nível II, com NQA = 1% para o limite inferior e 10% para o limite superior, com variabilidade desconhecida, desvio-padrão.

O inspetor de qualidade, baseado nos procedimentos adotados para inspeção por amostragem nos lotes anteriores, coletou uma amostra de seis unidades, medindo-as. Os resultados da medição são apresentados a seguir.

Amostra	Valor
1	199,01
2	178,78
3	180,03
4	204,82
5	180,11
6	208,99

Com base no exposto, responda:

1. A decisão do inspetor quanto à amostra foi correta? Justifique a resposta.

2. O lote deve ser aceito? Justifique a resposta.

3. Como devem ser inspecionados os próximos lotes do produto X vindos deste fornecedor?

Resposta comentada

1. Como o fornecedor entregou nove lotes consecutivos aceitos em inspeção normal, ele deve permanecer sendo inspecionado pelo plano normal, visto que ele só passaria à inspeção atenuada após 10 lotes consecutivos aceitos (vide **Figura 12.3**). Além disso, como se trata de um lote de 50 peças, inspeção geral nível II, o tamanho da amostra deve ser de seis unidades (vide **Tabela 12.2**). Desta forma, as decisões do inspetor foram adequadas.

2. Para avaliarmos o lote, devemos seguir o fluxo mostrado na **Figura 12.7**. Assim, devemos calcular os índices de qualidade Qi e Qs e, para tanto, precisamos calcular a média da amostra e seu desvio-padrão, bem como os limites superior e inferior da especificação. Temos, então, os seguintes valores:

Calculamos, então :

$$\bar{x} = \frac{199,01 + 178,78 + 180,03 + 204,82 + 180,11 + 208,99}{6} = 191,96mm$$

Podemos, também, calcular s:

$$s = \sqrt{\frac{(199,01 - 191,96)^2 + (178,78 - 191,96)^2 + (180,03 - 191,96)^2 + (204,82 - 191,96)^2 + (180,11 - 191,96)^2 + (208,99 - 191,96)^2}{6 - 1}} = 13,87mm$$

Os valores superior e inferior da especificação podem ser calculados:

LSE = 195 + 14,3 = 209,3 mm; e

LIE = 195 - 16,9 = 178,1 mm.

Desta forma, os valores de Qs e Qi são:

$$Q_s = \frac{209,3 - 191,96}{13,87} = 1,25 \quad \text{e} \quad Q_i = \frac{191,96 - 178,1}{13,87} = 1,00$$

Como nem Q_s nem Q_i são negativos, continuamos a análise (lembre-se que, caso ao menos um fosse negativo, o lote seria rejeitado).

Consultamos, então, a **Tabela 12.6**, para estimar os percentuais defeituosos p_i e p_s , como mostrado a seguir:

Qi & Qs	Tamanho da amostra			
	3	4	6	9
0,90	21,55	20,00	19,08	18,76
1,00	16,67	16,67	16,19	16,02
1,25	0,00	8,33	9,79	10,14
1,50	0,00	0,00	4,68	5,63

Temos, assim que $p_i = 16,19\%$ e $p_s = 9,79\%$. Tais valores precisam ser comparados com as porcentagens máximas admissíveis M_i e M_s , as quais podem ser obtidas na **Tabela 12.4**, como mostrado a seguir:

NQA	Tamanho da amostra			
	3	4	6	9
0,10	0,24	0,24	0,24	0,24
0,15	0,47	0,47	0,47	0,47
0,25	0,69	0,69	0,69	0,69
1,0	3,09	3,09	3,09	3,09
2,5	8,00	8,00	8,00	6,94
10	33,33	33,33	32,01	28,52

Ou seja, $M_i = 3,09\%$ e $M_s = 32,01\%$. Observa-se, assim, que:

- $p_i > M_i$ ($16,19\% > 3,09\%$).
- $p_s < M_s$ ($9,79\% < 32,01\%$).
- $(p_i + p_s) < M_s$ ($16,19 + 9,79 = 25,98\% < 32,01\%$)

Desta forma, como $p_i > M_i$, o lote deve ser rejeitado, mesmo que $p_s < M_s$ e $(p_i + p_s) < M_s$.

3. Com a rejeição deste lote, o fornecedor não consegue alcançar o total de 10 lotes consecutivos aceitos e, desta forma, o próximo lote recebido continuará sendo inspecionado por inspeção normal. E, caso haja um segundo lote rejeitado dentre os próximos quatro lotes consecutivos recebidos, a inspeção deverá migrar para severa, por haverem dois lotes rejeitados em cinco consecutivos, como indicado na **Figura 12.3**.

Conclusão

Tanto na inspeção de recebimento por amostragem por atributos como por variáveis, devemos reconhecer que são ações tardias, por inspecionarmos o que já foi produzido e enviado, quando é preferível nos “anteciparmos ao problema”, utilizando, por exemplo, o controle dos processos por meio de cartas de controle.

Isso, porém, não significa que as inspeções de recebimento por amostragem devam ser abandonadas: elas têm o seu valor quando estamos lidando com um novo fornecedor, novos produtos, novos processos. Enquanto os processos não estiverem sob controle, estáveis e previsíveis, é necessário haver algum tipo de inspeção. E, nesse caso, a utilização da inspeção por amostragem é mais eficiente, rápida e barata que a inspeção 100%.

Resumo

A inspeção de recebimento por amostragem por variáveis segue basicamente a mesma lógica da por atributos, sendo, no entanto, mais complexa em termos de passos e de cálculos. Nela, trabalhamos principalmente com variabilidade desconhecida e o método do desvio-padrão, mas é possível, também, trabalharmos com o método da amplitude e com variabilidade conhecida.

Em comum com a inspeção por atributos, estabelecemos o tipo de inspeção (normal, severa ou atenuada) e o nível de inspeção (I, II, III, S1, S2, S3 e S4), bem como o NQA (nível de qualidade aceitável), tomando por base as normas NBR 5429: 1985 – Planos de amostragem

e procedimentos na inspeção por variáveis, e NBR 5430: 1985 – Guia de utilização da norma NBR 5429 – Planos de amostragem e procedimentos na inspeção por variáveis.

De acordo com as citadas normas, é possível, a partir do tamanho do lote, estabelecer os critérios de aceitação e rejeição do lote, comparando-se a estimativa de percentuais defeituosos com as porcentagens defeituosas máximas admissíveis e, a partir daí, aceitar ou rejeitar o lote.

Leitura recomendada

GALINA, Vanderlei. *Estudo e implementação computacional de planos amostrais para aceitação de lotes de produtos: normas ANSI/ASQ Z1.4 e ANSI/ASQ Z1.9*, 2009, 167 f. Dissertação (Mestrado), Curitiba, Universidade Federal do Paraná, 2009. Disponível em: <<https://acervodigital.ufpr.br/bitstream/handle/1884/24214/Vanderlei%20Galina.pdf;jsessionid=B99B1600865A26EBBB11007ACA592397?sequence=1>>. Acesso em: 19 Jun. 2019.

Referências

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. *ABNT NBR 5429: 1985* – Planos de amostragem e procedimentos na inspeção por variáveis. Rio de Janeiro: ABNT, 1985a.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. *ABNT NBR 5430: 1985* – Guia de utilização da norma NBR 5429 – Planos de amostragem e procedimentos na inspeção por variáveis. Rio de Janeiro: ABNT, 1985b.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. *ABNT NBR 6409: 1997* – Tolerâncias geométricas – Tolerâncias de forma, orientação, posição e batimento - Generalidades, símbolos, definições e indicações em desenho. Rio de Janeiro: ABNT, 1997.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. *Conheça a ABNT*. Rio de Janeiro: ABNT, 2014. Disponível em: <<http://www.abnt.org.br/abnt/conheca-a-abnt>>. Acesso em: 31 jul. 2019.

BESTERFIELD, Dale H. *Quality Control*. 3. ed. Englewood Cliffs: Prentice-Hall, 1990.

COSTA, Antônio Fernando Branco; EPPRECHT, Eugenio Kahn; CARPINETTI, Luiz César Ribeiro. *Controle estatístico de qualidade*. 2. ed. São Paulo: Atlas, 2016.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*. 4. ed. New York: John Wiley & Sons, 2001.

