

# Gráficos de controle para atributos

## CE219 - Controle Estatístico de Qualidade

Prof. Cesar Taconeli  
taconeli@ufpr.br

Prof. Walmes Zeviani  
walmes@ufpr.br

Laboratório de Estatística e Geoinformação  
Departamento de Estatística  
Universidade Federal do Paraná

10 de maio, 2019

# Qualidade em atributos

- ▶ Atributos são características da qualidade representadas por classificações, tais como **defeituoso/não defeituoso**; **conforme/não conforme**; **adequado/não adequado ao uso**, etc.
- ▶ Muitas vezes, tais classificações são resultantes do exame de múltiplas variáveis numéricas que caracterizam a qualidade.
- ▶ Dentre as principais modalidades de gráficos de controle para atributos, destacam-se:
  - ▶ Para a **fração** de itens não conformes.
  - ▶ Para o **tempo** entre itens não conformes.
  - ▶ Para o **número** de não conformidades.
  - ▶ Para a **taxa** de não conformidades.

# Exemplos de atributos

- ▶ **Proporção** de lâmpadas queimadas por lotes de 100 lâmpadas.
- ▶ **Tempo** entre sucessivas panes de um sistema de produção.
- ▶ **Número** de imperfeições em rolos de papel acabados.
- ▶ **Taxa** (número) de imperfeições por metro quadrado de tecido produzido.



# Gráficos de controle para atributos

# A fração de itens não conformes

- ▶ Suponha um processo que produza **itens não conformes** com probabilidade  $0 < p < 1$ .
- ▶ Vamos considerar o monitoramento desse processo com base em amostras de  $n$  itens selecionadas periodicamente.
- ▶ Seja  $X$  a variável aleatória correspondente ao **número de itens não conformes** na amostra. Assumindo **independência** entre os itens, sabemos que:

$$X \sim \text{Binomial}(n, p), \quad E(X) = np, \quad \text{Var}(X) = np(1 - p).$$

# Distribuição para a fração não conforme

- ▶ Define-se a **fração amostral de itens não conformes** por meio da seguinte proporção:

$$\hat{p} = \frac{X}{n}.$$

- ▶ Pode-se verificar facilmente que:

$$E(\hat{p}) = p, \quad \text{Var}(\hat{p}) = \frac{p(1-p)}{n}.$$

- ▶ De acordo com o teorema central do limite, para  $n \rightarrow \infty$ :

$$\hat{p} \sim \text{Normal} \left( \mu_{\hat{p}} = p, \sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{n}} \right).$$

# Limites de controle para a fração não conforme

Assumindo  $p = p_0$  a probabilidade de produção de itens não conformes para o processo operando **sob controle**, os limites do gráfico de controle para a fração de não conformes ficam dados por:

$$\text{LSC} = p_0 + 3\sqrt{\frac{p_0(1 - p_0)}{n}}$$

$$\text{LC} = p_0$$

$$\text{LIC} = p_0 - 3\sqrt{\frac{p_0(1 - p_0)}{n}}$$

## Exercício

Considere que determinado processo, operando sob controle, produza itens não conformes com probabilidade 0.05. O processo será monitorado com base em um gráfico de controle  $3\sigma$  para a fração de não conformes, com  $n = 100$ . Determine a linha central e os limites de controle e de alerta do gráfico.



# Solução

```
n <- 100 1
p0 <- 0.05 2
n_sigmas <- 3 3
p0 + c(LIC = -1, LC = 0, LSC = 1) * n_sigmas * sqrt(p0 * (1 - p0)/n) 4
5
```

```
#          LIC          LC          LSC
# -0.01538348  0.05000000  0.11538348
```

## Estimação da fração não conforme

- ▶ Se a probabilidade de produção de itens não conformes (sob controle) for desconhecida, **precisamos estimá-la** com base em dados de uma primeira fase da construção do gráfico de controle.
- ▶ Sejam  $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_m$  as frações de itens não conformes em  $m$  amostras de tamanho  $n$  do processo operando sob controle.
- ▶ Um estimador não viciado de  $p$  é dado por:

$$\bar{p} = \frac{\sum_{i=1}^m \hat{p}_i}{m}.$$

# Gráficos de controle para a fração não conforme

Os limites do gráfico de controle para a fração de não conformes, com  $p_0$  estimado, ficam dados por:

$$\text{LSC} = \bar{p} + 3\sqrt{\frac{\bar{p}(1 - \bar{p})}{n}}$$

$$\text{LC} = \bar{p}$$

$$\text{LIC} = \bar{p} - 3\sqrt{\frac{\bar{p}(1 - \bar{p})}{n}}$$

## Exercício

São apresentados os números de montagens não conformes em  $m = 20$  amostras de tamanho  $n = 100$ . Faça o gráfico da fração de não conformes.

Amostra	Não conformes	Amostra	Não conformes
1	6	11	7
2	15	12	4
3	0	13	1
4	9	14	3
5	5	15	6
6	1	16	8
7	4	17	10
8	5	18	5
9	7	19	2
10	12	20	7

# Solução

---

```
n <- 100
x <- c(6, 15, 0, 9, 5, 1, 4, 5, 7, 12, 7, 4, 1, 3, 6, 8, 10, 5, 2, 7)
m <- length(x)

p <- x/n
pm <- mean(p) # Ou: mean(x/n)

n_sigmas <- 3
lims <- pm + c(LIC = -1, LC = 0, LSC = 1) *
  n_sigmas * sqrt(pm * (1 - pm)/n)
lims
```

---

#	LIC	LC	LSC
#	-0.01190595	0.05850000	0.12890595

---

```
plot(x/n, type = "o", pch = 19, ylim = range(p, lims))
abline(h = lims, col = 1, lty = 2)
```

---

# Tamanhos de amostra variáveis

- ▶ Caso as amostras disponíveis tenham **diferentes tamanhos**, os limites de controle devem ser devidamente ajustados.
- ▶ Seja  $n_i$  o tamanho da  $i$ -ésima amostra ( $i = 1, 2, \dots$ ). Os limites do gráfico de controle para a fração de não conformes ficam dados por:

$$LSC_i = p_0 + 3\sqrt{\frac{p_0(1 - p_0)}{n_i}}$$

$$LC = p_0$$

$$LIC_i = p_0 - \sqrt{\frac{p_0(1 - p_0)}{n_i}}.$$

## Tamanhos de amostra variáveis

- ▶ Caso  $p_0$  não seja especificado, **devemos estimá-lo** com base em  $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_m$ , as frações de itens não conformes em  $m$  amostras do processo sob controle (com respectivos tamanhos  $n_1, n_2, \dots, n_m$ ).
- ▶ Nesse caso,  $p_0$  fica estimado por:

$$\bar{p} = \frac{\sum_{i=1}^m n_i \hat{p}_i}{\sum_{i=1}^m n_i}.$$

- ▶ Os limites do gráfico de controle para a fração de não conformes ficam dados por:

$$LSC_i = \bar{p} + 3\sqrt{\frac{\bar{p}(1 - \bar{p})}{n_i}}$$

$$LC = \bar{p}$$

$$LIC_i = \bar{p} - 3\sqrt{\frac{\bar{p}(1 - \bar{p})}{n_i}}.$$

# Planejamento do gráfico de controle para atributos

- ▶ Assim como no caso dos gráficos de controle para variáveis, o **planejamento** de gráficos de controle para a fração de não conformes é uma etapa fundamental do processo.
- ▶ Dentre os **fatores** a serem considerados no planejamento, destacam-se:
  - ▶ O **tamanho** das amostras.
  - ▶ A **frequência** de amostragem.
  - ▶ A **amplitude** dos limites de controle ( $3\sigma$ ?).
  - ▶ A constituição de **sub-grupos racionais**.



# Planejamento do gráfico de controle para atributos

Várias regras são sugeridas na literatura para a escolha de  $n$ , dentre as quais:

- ▶ Determinar  $n$  tal que se tenha uma probabilidade no **mínimo** igual a  $\gamma$  de encontrar ao menos uma unidade não conforme na amostra com o processo operando sob controle.
- ▶ Determinar o tamanho de amostra  $n$  tal que a probabilidade de **detectar** uma alteração  $\delta$  na fração de itens não conformes, numa particular amostra, seja 0,5;
- ▶ Determinar o tamanho amostral  $n$  tal que o gráfico de controle tenha  $LIC > 0$ .

# Exercício

Um processo operando sob controle produz fração de não conformes 0.05 e será monitorado com base em um gráfico de controle com limites  $3\sigma$ . Qual deve ser o tamanho amostral ( $n$ ) tal que:

- ▶ Se tenha 90% de probabilidade de uma amostra de tamanho  $n$  conter ao menos um item não-conforme?
- ▶ Se tenha um LIC positivo?
- ▶ Se tenha 50% de probabilidade de detectar uma alteração na fração de não conformes para  $p = 0.11$ ?

# Solução

```
# |Pr("pelo menos um item não conforme") é o mesmo que calcular  
# 1 - |Pr("nenhum item não conforme") = 1 - |Pr(X = 0).  
  
n_sigmas <- 3  
p0 <- 0.05  
  
# 1- |Pr(X = 0 | n = n, p_0 = p)  
n <- 1:100  
prob <- 1 - pbinom(q = 0, size = n, prob = p0)  
head(prob)  
  
# [1] 0.0500000 0.0975000 0.1426250 0.1854938 0.2262191 0.2649081
```

```
i <- which(prob >= 0.9)[1]  
list(n = n[i], prob = prob[i])  
  
# $n  
# [1] 45  
#  
# $prob  
# [1] 0.9005597
```

```
1 - pbinom(q = 0, size = n[i], prob = p0)  
  
# [1] 0.9005597
```

# Solução

```
# Se  $LIC = p\theta - n\_sigmas * \sqrt{p\theta * (1 - p\theta)/n} > \theta$ , então  
#  $n > p\theta * (1 - p\theta)/(p\theta/n\_sigmas)^2$ 
```

```
n_min <- ceiling(pθ * (1 - pθ)/(pθ/n_sigmas)^2)  
n_min
```

```
# [1] 171
```

```
pθ - n_sigmas * sqrt(pθ * (1 - pθ)/((n_min - 3):(n_min + 3)))
```

```
# [1] -0.0004444532 -0.0002949878 -0.0001468432 0.0000000000  
# [5] 0.0001455607 0.0002898575 0.0004329086
```

# Solução

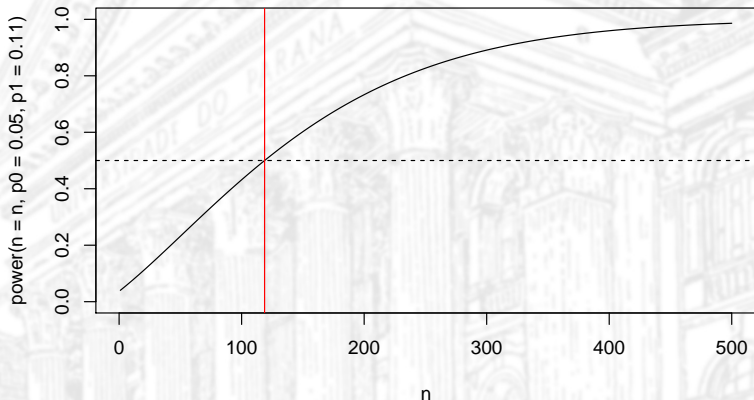
```
# Função poder. 1
# ATTENTION: usando aproximação Normal. 2
power <- function(n, p0, p1, n_sigmas = 3) { 3
  sd_p0 <- sqrt(p0 * (1 - p0)/n) 4
  lim <- p0 + c(-1, 1) * n_sigmas * sd_p0 5
  sd_p1 <- sqrt(p1 * (1 - p1)/n) 6
  1 - (pnorm(lim[2], mean = p1, sd = sd_p1) - 7
      pnorm(lim[1], mean = p1, sd = sd_p1)) 8
} 9
power <- Vectorize(FUN = power, vectorize.args = "n") 10
# Encontra a raiz para determinar o n para Pr(.) = 0.5. 11
n_sol <- uniroot(f = function(x, ...) power(n = x, ...) - 0.5, 12
                interval = c(1, 500), 13
                p0 = 0.05, p1 = 0.11, n_sigmas = 3) 14
ceiling(n_sol$root) 15
# [1] 119 16
```

# Solução

# Gráfico.

```
curve(power(n = n, p0 = 0.05, p1 = 0.11),  
      xname = "n", from = 1, to = 500, ylim = c(0, 1))  
abline(h = 0.5, lty = 2)  
abline(v = n_sol$root, col = "red")
```

1  
2  
3  
4  
5



# Função característica de operação

- ▶ A probabilidade do **erro do tipo II** para o gráfico de controle para a fração de itens não conformes é dada, para algum  $p \neq p_0$ , por:

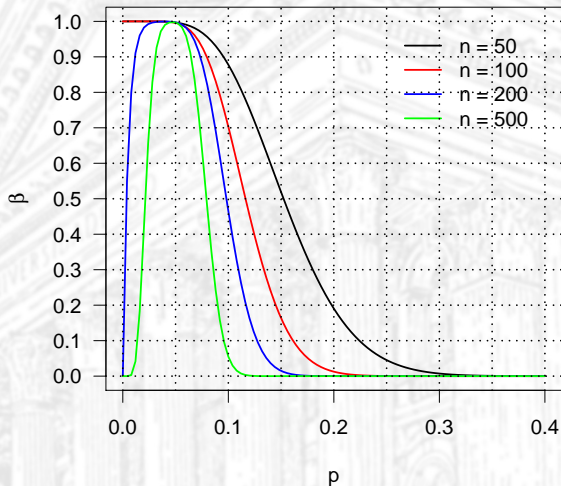
$$\beta(p) = \Pr(\hat{p} < \text{LSC}|p) - \Pr(\hat{p} \leq \text{LIC}|p).$$

- ▶ De maneira equivalente, multiplicando ambos os termos de cada desigualdade por  $n$ , temos:

$$\beta(p) = \Pr(X < n\text{LSC}|p) - \Pr(X \leq n\text{LIC}|p).$$

- ▶ Como  $X \sim \text{Binomial}(n, p)$ ,  $\beta(p)$  pode ser calculado diretamente da distribuição binomial acumulada. Os comprimentos médios de sequência são calculados da maneira usual (invertendo as respectivas probabilidades).

# Curvas características de operação





## Código para o erro tipo II

```
erro_tipo_II <- function(p, n, p0, n_sigmas = 3) { 1
  # Limites baseados na Normal. 2
  sd_p0 <- sqrt(p0 * (1 - p0)/n) 3
  lim <- p0 + c(-1, 1) * n_sigmas * sd_p0 4
  # Probabilidades baseadas na binomial. 5
  X <- n * lim 6
  pbinom(floor(X[2]), size = n, prob = p) - 7
  pbinom(floor(X[1]) - 1, size = n, prob = p) 8
} 9
erro_tipo_II <- Vectorize(FUN = erro_tipo_II, 10
  vectorize.args = c("p", "n")) 11
# Usando os dados encontrados antes. 12
1 - erro_tipo_II(p = 0.11, n = 119, p0 = 0.05, n_sigmas = 3) 13
14
```

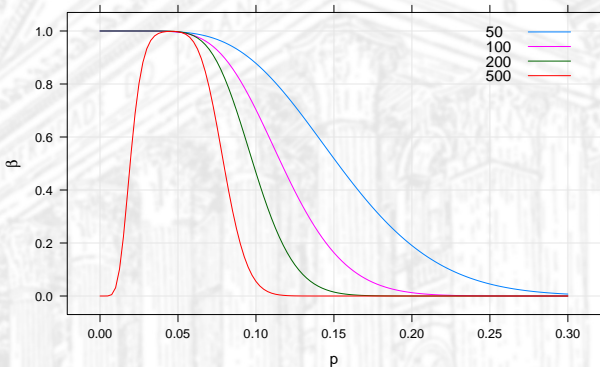
```
# [1] 0.4373189
```

```
grid <- expand.grid(n_seq = c(50, 100, 200, 500), 1
  p_seq = seq(0, 0.3, by = 0.0025)) 2
grid$erro <- with(grid, 3
  erro_tipo_II(p = p_seq, 4
    n = n_seq, 5
    p0 = 0.05, 6
    n_sigmas = 3)) 7
```

# Gráfico da curva característica de operação

```
library(lattice)
xyplot(erro ~ p_seq, groups = n_seq, data = grid,
       grid = TRUE, type = "l",
       auto.key = list(corner = c(0.95, 0.95),
                       points = FALSE, lines = TRUE),
       xlab = "p", ylab = expression(beta))
```

1  
2  
3  
4  
5  
6



## Exercício

Um processo operando sob controle produz fração de não conformes 0.05. Amostras de tamanho  $n = 200$  serão extraídas a fim de inspecionar o processo com relação a  $p$ .

- ▶ Determine os limites de controle do gráfico da fração de não conformes.
- ▶ Calcule o valor de  $\alpha$  (forneça os valores obtidos pela aproximação com a distribuição normal e pela binomial).
- ▶ Usando os resultados do item anterior, apresente o número esperado de amostras até se ter um falso alarme.
- ▶ Calcule o valor de  $\beta$  se o processo passar a produzir uma fração de não-conformes de 0.08.
- ▶ Obtenha as curvas características de operação para amostras de tamanhos  $n = 5, 10, 25, 50$  e 100.

# Solução

---

```
p0 <- 0.05 1
n_sigmas <- 3 2
n <- 200 3

# Limites de controle. 4
lim <- p0 + c(LIC = -1, LC = 0, LSC = 1) * 5
      n_sigmas * sqrt(p0 * (1 - p0)/n) 6
lim 7 8 9

# Erros tipo 1. 10
alpha_nor <- power(n = n, p0 = p0, p1 = p0, n_sigmas = n_sigmas) 11
alpha_bin <- 1 - erro_tipo_II(p = p0, n = n, p0 = p0, 12
                             n_sigmas = n_sigmas) 13
c(alpha_nor, alpha_bin) 14 15

# Número esperado de amostras. 16
c(1/alpha_nor, 1/alpha_bin) 17 18

# Se o processo estiver com p = 0.08. 19
erro_tipo_II(p = 0.08, n = n, p0 = p0, n_sigmas = n_sigmas) 20
```

---

## Processos com níveis baixos de defeitos

- ▶ Processos com **níveis muito baixos** de defeitos vão apresentar itens não conformes com frequência muito baixa.
- ▶ Os gráficos de controle apresentados para a fração de itens não conformes **não funcionam** bem em tais circunstâncias.
- ▶ Nesse caso, uma alternativa é monitorar o **tempo entre ocorrências** de itens não conformes.
- ▶ Se a contagem de eventos não conformes é bem modelada pela distribuição **Poisson**, então o tempo entre ocorrências tem distribuição **exponencial** (processo de Poisson).

# Distribuição exponencial

- ▶ No entanto, a distribuição exponencial é fortemente **assimétrica**, o que poderia dificultar a aplicação e a interpretação dos gráficos de controle.
- ▶ Uma **transformação** aplicada a dados com distribuição exponencial que proporciona boa aproximação com a distribuição Normal é dada por:

$$x = y^{1/3.6} = y^{0.277}$$

- ▶ Dessa forma, a análise poderia ser realizada, por exemplo, aplicando-se gráficos de controle para observações individuais para  $x$ .

# Exemplo

Tabela 1. Registros de 29 homicídios em certa localidade do Texas.

Data	Dias entre	Data	Dias entre	Data	Dias entre
Jan-20		Jun-16	9	Set-24	2
Fev-23	34	Jun-16	0	Out-01	7
Fev-25	2	Jun-22	6	Out-04	3
Mar-05	8	Jun-25	3	Out-08	4
Mar-10	5	Jul-06	11	Out-19	11
Abr-04	25	Jul-08	2	Nov-02	14
Mai-07	33	Jul-09	1	Nov-25	23
Mai-24	17	Jul-26	17	Dez-28	33
Mai-28	4	Set-09	45	Dez-29	1
Jun-07	10	Set-22	13		

# Número de não conformidades

- ▶ Em determinados processos, os itens produzidos podem apresentar certo **número** de pequenas não conformidades que não o caracterizam como um item não conforme.
- ▶ No entanto, um grande número de pequenas não conformidades pode ser **perceptível** (e indesejável) ao consumidor.
- ▶ O monitoramento de frequências, como, por exemplo, a frequência de pequenas não conformidades em produtos, é um objetivo frequente no controle estatístico de qualidade.



# Exemplos



- ▶ Número de pequenas irregularidades em amostras de tecido.
- ▶ Número de avarias no acabamento de automóveis.
- ▶ Número de requisições de assistência técnica de máquinas de lavar nos dois primeiros anos de uso.
- ▶ Número de erros produzidos por um programa de computador.

# Condições para a distribuição Poisson

As frequências sob monitoramento serão adequadamente modeladas pela distribuição de **Poisson** se as seguintes **condições** forem satisfeitas:

- ▶ As não conformidades ocorrem de maneira **aleatória** em cada unidade de inspeção;
- ▶ Tenha-se probabilidade **constante** de não conformidades ao longo da unidade de inspeção;
- ▶ O número de **oportunidades** de localização de não conformidades em cada unidade de inspeção é infinitamente grande.

# Unidades de inspeção

- ▶ Vamos considerar inicialmente unidades de inspeção de **mesmo tamanho** (mesmo número de itens ou mesma quantidade de produto).
- ▶ As unidades de inspeção podem ser um único produto, um conjunto de produtos, certo volume de produção, etc.
- ▶ Vamos admitir que o número de **não conformidades por unidade** de inspeção seja uma variável aleatória  $X \sim \text{Poisson}(c)$ :

$$\Pr(X = x) = \frac{\exp\{-c\} \cdot c^x}{x!} \quad x = 0, 1, 2, \dots$$

# Limites de controle

O gráfico de controle para não conformidades fica especificado por:

$$\text{LSC} = c_0 + 3\sqrt{c_0}$$

$$\text{LC} = c_0$$

$$\text{LIC} = c_0 - 3\sqrt{c_0},$$

se houver algum valor especificado para  $c_0$ , a **taxa de não conformidades** para o processo sob controle.

# Estimação da taxa de não conformidades

- ▶ Caso não se disponha de um valor para  $c_0$ , **devemos estimá-lo** com base em dados de  $m$  amostras da fase I do processo.
- ▶ Sejam  $c_1, c_2, \dots, c_m$  os números de não conformidades nas  $m$  amostras. Podemos estimar  $c_0$  por

$$\bar{c} = \sum_{i=1}^m c_i / m.$$

- ▶ Os limites de controle ficam estabelecidos por:

$$\text{LSC} = \bar{c} + 3\sqrt{\bar{c}}$$

$$\text{LC} = \bar{c}$$

$$\text{LIC} = \bar{c} - 3\sqrt{\bar{c}}.$$

# Exercício

Um gráfico de controle semelhante ao usado para a frequência de não conformidades é aplicado ao monitoramento do número de cirurgias de grande porte requeridas diariamente por clientes de um plano de saúde. Em condições normais têm-se, em média, 5 requisições por dia. Com base nessas informações:

- ▶ Estabeleça os limites de controle  $3\sigma$ .
- ▶ Calcule  $\alpha$ , a probabilidade do erro do tipo I, e o correspondente CMS.
- ▶ Calcule  $\beta(10)$ , a probabilidade do erro do tipo II, caso o número médio diário de requisições aumente para 10.

# Solução

---

```
# Limites de controle pela distribuição normal.  
c0 <- 5; n_sigmas <- 3  
lim <- c0 + c(-1, 0, 1) * n_sigmas * sqrt(c0); lim
```

```
# [1] -1.708204 5.000000 11.708204
```

---

```
# Cuidados para quando a distribuição é discreta.  
li <- max(0, floor(min(lim)))  
lu <- ceiling(max(lim))
```

```
# Taxa de erro tipo I.  
alpha <- ppois(li - 1, lambda = c0) +  
         ppois(lu, lambda = c0, lower.tail = FALSE)  
alpha
```

```
# [1] 0.002018852
```

---

```
# Taxa de erro tipo II.  
alpha <- ppois(li - 1, lambda = 10) +  
         ppois(lu, lambda = 10, lower.tail = FALSE)  
1 - alpha
```

```
# [1] 0.7915565
```

---

## Tamanho de amostra variável

- ▶ Os gráficos de controle para não conformidades não requerem a avaliação de uma única unidade de inspeção, nem mesmo que o número (tamanho) de unidades de inspeção seja o mesmo nas diferentes amostras.
- ▶ Voltando ao exemplo anterior, podemos monitorar a taxa de não conformidades por placa de circuito impresso, com base em amostras de  $n = 100$  placas.
- ▶ Ainda, o monitoramento da taxa de não conformidades por  $m^2$  de papel produzido pode-se dar com base em amostras de **dimensões variáveis**, como 10, 5, 2.5  $m^2$ , etc.



# Número médio de não conformidades

- ▶ Uma abordagem adequada nesse tipo de situação é utilizar o **número médio de não conformidades por unidade de inspeção** em cada amostra.
- ▶ Seja  $c$  o número de não conformidades em uma amostra de tamanho  $n$  (note que  $n$  não precisa ser um número inteiro).
- ▶ O número médio de não conformidades por unidade de inspeção (ou taxa de não conformidades) nessa amostra fica definido por:

$$u = \frac{c}{n}.$$

## Limites de controle

Sejam  $c_1, c_2, \dots, c_m$  os números médios de não conformidades em amostras de tamanho  $n_1, n_2, \dots, n_m$ . Os limites do gráfico de controle para a taxa de não conformidades, baseados nesse conjunto de amostras, ficam definidos por:

$$\text{LSC}_i = \bar{u} + 3\sqrt{\frac{\bar{u}}{n_i}}$$

$$\text{LC} = \bar{u}$$

$$\text{LIC}_i = \bar{u} - 3\sqrt{\frac{\bar{u}}{n_i}}, \quad \bar{u} = \frac{\sum_{i=1}^m c_i}{\sum_{i=1}^m n_i}.$$

# Exercício

Um processo de produção de cabos elétricos começará a ser monitorado. Foram coletadas 20 amostras, dispondo-se da quantidade de fio (em metros) e do número de defeitos. Dados e códigos estão disponíveis na página da disciplina.

- ▶ Estabeleça um gráfico de controle adequado com base nos dados disponíveis.
- ▶ Qual sua estimativa para a taxa de defeitos por 10000 m de cabo?
- ▶ O processo aparenta estar sob controle?
- ▶ Como é muito caro inspecionar cerca de 10000 m de cabo, os gerentes propõem reduzir o tamanho de amostra para 2500 m. Como ficariam os limites de controle?

# Causas de não conformidades

- ▶ Uma sequência natural para a análise da taxa de não conformidades é a descrição das **causas de não conformidades**.
- ▶ Para isso, pode-se proceder com o registro não só do número de não conformidades por amostra, mas também das respectivas causas.
- ▶ A análise das frequências das diferentes causas de não conformidades pode fundamentar possíveis **intervenções** para a melhoria da qualidade.
- ▶ O **gráfico de Pareto** é uma ferramenta útil para visualização das frequências de causas de não conformidades distintas.

# Exemplo




Figura 2. Exemplo de gráfico de Pareto empregado na análise do número de casos de devolução de produtos comprados online. Fonte: <https://blogdaqualidade.com.br/diagrama-de-pareto/>.

# Diagrama de causa e efeito

- ▶ O **diagrama de causa e efeito** (gráfico espinha de peixe) é uma ferramenta eficiente para ilustração das relações de causas e efeitos.
- ▶ Num organograma no formato de espinha de peixe:
  - ▶ O efeito (problema a ser resolvido) é representado na extremidade principal (cabeça do peixe).
  - ▶ As (possíveis) causas principais são representadas nas demais extremidades.
  - ▶ As causas secundárias, associadas às causas principais, são representadas nos espinhos correspondentes.

# Exemplo

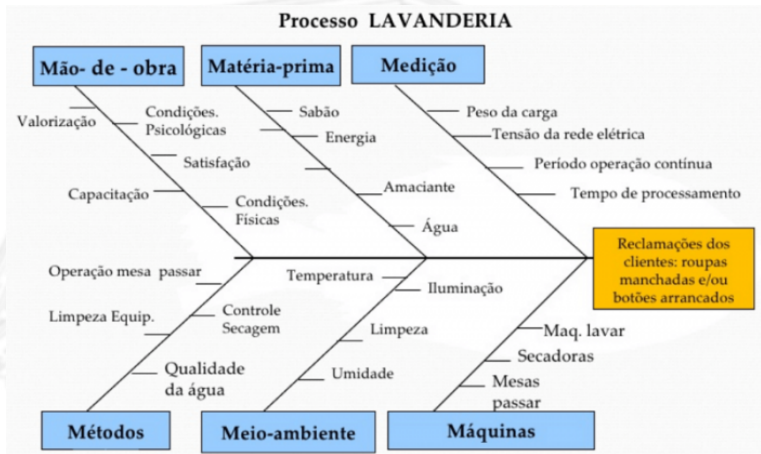


Figura 3. Diagrama de causa e efeito para ilustrar as causas de não conformidade em uma lavanderia. Fonte: <https://www.gp4us.com.br/diagrama-de-causa-e-efeito-ishikawa-na-pratica/>.

# Exercício

O gerente de uma pizzaria delivery observou significativa queda no número de compras por telefone ou aplicativo no último mês. Estabeleça um diagrama de causa e efeito que tenha como efeito a diminuição do número de encomendas. Relacione ao menos cinco causas principais e duas causas secundárias associadas a cada uma delas.