

# Análise de Dados Categorizados - Aula1

Márcia D Elia Branco

Universidade de São Paulo  
Instituto de Matemática e Estatística  
[www.ime.usp.br/~mbranco](http://www.ime.usp.br/~mbranco) - sala 295-A -

- **Variáveis categóricas:** são variáveis qualitativas, com um número finito de categorias disjuntas de respostas. Podem estar na escala *nominal* ou *ordinal*.
- Variáveis com apenas duas categorias são denominadas *dicotômicas* ou *binárias*.
- Variáveis com três ou mais categorias são denominadas *politômicas*.
- Variáveis numéricas discretas ou contínuas também podem ser categorizadas.
- Variáveis respostas x Variáveis explicativas (fatores ou covariáveis).
- As técnicas de dados categorizados estudadas aqui referem-se basicamente à característica categórica da variável resposta.

- Tabela de contingência de dupla entrada ( $r \times c$ ): envolve apenas duas variáveis categóricas.
- $n_{ij}$  representa a frequência observada na linha  $i$  coluna  $j$  da tabela.
- $n_{i+}$  representa a soma da linha  $i$ .
- $n_{+j}$  representa a soma da coluna  $j$ .
- $\sum_{i=1}^r \sum_{j=1}^c n_{ij} = n_{++} = n$
- $N_{ij}$  denota a variável aleatória associada a observação  $n_{ij}$ .
- $p_{ij} = P(X = i, Y = j)$ ,  $p_{i+} = P(X = i)$  e  $p_{+j} = P(Y = j)$ .
- Tabelas com múltiplas entradas ( $q \times r \times c$ ): três ou mais variáveis categóricas .

**Exemplo 1:** O interesse é comparar dois vermífugos. Para isso o pesquisador selecionou 400 carneiros da mesma raça, todos sem verminose, mantendo-os sob o mesmo manejo em pastos com condições similares. A seguir, separam-se os animais aleatoriamente em dois grupos de tamanhos iguais e, para cada um, administrou-se um de dois vermífugos. Decorridos 4 meses os animais foram examinados.

Vermífugo	Verminose		Totais
	Sim	Não	
1	48	152	200
2	68	132	200
Totais	116	284	400

**Exemplo 2:** Durante 18 semanas de determinado ano foi contado o número de acidentes de carros registrados na Suécia, avaliando-se o tipo de estrada e o fato de haver ou não um limite de velocidade. O objetivo é verificar se o limite de velocidade influencia de maneira diferente o número de acidentes dependendo do tipo de estrada.

Limite de velocidade	Tipo de estrada		Totais
	Auto-estrada	Outra	
Sim	8	42	50
Não	57	106	163
Totais	65	148	213

## 1. Estudos Longitudinais (de Coorte ou Prospectivos):

- Inicia-se com um grupo de indivíduos todos livres da doença sob investigação.
- Esse grupo é classificado como *Exposto* ou *Não Exposto* a um determinado agente (fator de risco), obtendo-se dois grupos (coortes).
- Observa-se os dois grupos por um período de tempo, registra-se o número de indivíduos que desenvolveram a doença nesse período.
- Nota-se que os totais  $n_{1+}$  (expostos) e  $n_{2+}$  (não expostos) são fixados previamente.

## 2. Estudos caso-controle:

- Seleciona-se um grupo de indivíduos com uma determinada doença, denominado *casos* .
- Escolhe-se um outro grupo de indivíduos sem a doença, com características similares ao primeiro, denominado *controle*.
- Estabelecidos os grupos, registram-se os indivíduos *expostos* e *não expostos* ao fator de risco sob investigação.
- Esses estudos são denominados *retrospectivos*, pois usam informações do passado.
- Nota-se que os totais  $n_{+1}$  (casos) e  $n_{+2}$  (controle) são fixados previamente.

## 3. Estudos transversais:

- Informações sobre várias características são obtidas simultaneamente.
- Difícil inferir causalidade.
- Neste caso, somente  $n$  é fixado, as demais quantidades são observações de variáveis aleatórias.

## 4. Ensaio clínico aleatorizado:

- Usualmente usado para comparar dois ou mais tratamentos.
- Inicia-se com um grupo de indivíduos elegíveis, todos livres da doença sob investigação.
- Os tratamentos de interesse são alocados aleatoriamente aos indivíduos elegíveis.
- Observa-se os grupos (definidos pelo tratamento alocado) por um período de tempo, registra-se o número de indivíduos que desenvolveram a doença nesse período. Estudo *prospectivo*
- Nota-se que os totais  $n_{1+}$  (expostos) e  $n_{2+}$  (não expostos) são fixados previamente.

**Exemplo 3:** Um estudo foi realizado para pesquisar a associação entre tabagismo e câncer de pulmão. Foram considerados dois grupos de indivíduos: o primeiro com indivíduos com câncer e o segundo com indivíduos sem a doença. Em seguida, investigou-se sobre o histórico de exposição ao tabaco dos dois grupos. Os dados são apresentados na tabela a seguir.

Exposição ao tabaco	Câncer		Totais
	Sim	Não	
Sim	75	45	120
Não	21	56	77
Totais	96	101	197

**Exemplo 4:** Na Faculdade de Medicina de Ribeirão Preto selecionou-se 8135 fichas hospitalares referentes aos nascimentos ocorridos num certo período de tempo. Os nascimentos foram classificados em relação as variáveis: Classe Social (em 5 níveis, decrescentemente ordenada da mais favorecida pra menos favorecida); Hábito de Fumar (em 2 níveis) da parturiente e Peso do recém-nascido (em 3 níveis).

Peso RN	< 2.5 kg		2.5 - 3.0 kg		> 3.0 kg	
	HFumar		HFumar		HFumar	
Classe Social	Sim	Não	Sim	Não	Sim	Não
A	2	5	11	24	31	95
B	3	11	32	57	91	238
C	15	25	58	105	134	445
D	94	105	225	339	340	1053

# Modelos probabilísticos em tabelas de dupla entrada

- Modelo produto de binomiais: os totais marginais das linhas (ou colunas) são fixados pelo plano amostral. Associado a tabelas  $r \times 2$  (ou  $2 \times c$ ).
- Modelo produto de multinomias: os totais marginais das linhas (ou colunas) são fixados pelo plano amostral. Associado a tabelas  $r \times c$ .
- Modelo multinomial: somente o tamanho total da amostra ( $n$ ) é fixado pelo plano.
- Modelo produto de Poisson: observações são realizadas num período de tempo. O tamanho da amostra não é fixado previamente.

Ilustramos com o Exemplo 1.

$N_{11}$  é o número de indivíduos com verminose no grupo 1 e

$N_{21}$  é o número de indivíduos com verminose no grupo 2.

$$N_{i1} \sim \text{Binomial}(200, p_{(i)1}) \quad i = 1, 2$$

Em que  $p_{(i)1}$  é uma probabilidade condicional dada por

$$p_{(i)1} = \frac{p_{i1}}{p_{i+}}$$

Sob a hipótese de amostras independentes temos a seguinte função de verossimilhança

$$L(p_{(1)1}, p_{(2)1}) = \prod_{i=1}^2 C_{n_{i1}}^{n_{i+}} p_{(i)1}^{n_{i1}} (1 - p_{(i)1})^{n_{i+} - n_{i1}}$$

**Exemplo 5:** A tabela a seguir apresenta o resultado de um ensaio clínico aleatorizado.

Tratamento	Melhora do paciente			Totais
	Nenhuma	Alguma	Acentuada	
Ativo	13	07	21	41
Placebo	29	07	07	43
Totais	42	14	28	84

Para o grupo 1 (ativo) temos

$$(N_{11}, N_{12}) \sim \text{Multinomial}(41, (p_{(1)1}, p_{(1)2}, p_{(1)3}))$$

Isto é,

$$P(N_{11} = n_{11}, N_{12} = n_{12}) = \frac{n_{1+}!}{n_{11}!n_{12}!n_{13}!} \prod_{j=1}^3 p_{(1)j}^{n_{1j}}$$

Em que

$$p_{(1)3} = 1 - p_{(1)1} - p_{(1)2} \text{ e } n_{13} = n_{1+} - n_{11} - n_{12}$$

Equivalentemente para o grupo 2 (placebo).

A função de verossimilhança (supondo independência)

$$L(p_{(1)1}, p_{(1)2}) \propto \prod_{i=1}^2 \prod_{j=1}^3 p_{(i)j}^{n_{ij}}$$

Para tabelas  $r \times c$  a verossimilhança é proporcional a

$$\prod_{i=1}^r \prod_{j=1}^c p_{(i)j}^{n_{ij}}$$

em que

$$p_{(i)c} = 1 - \sum_{j=1}^{c-1} p_{(i)j} \quad \text{e} \quad n_{ic} = n_{i+} - \sum_{j=1}^{c-1} n_{ij}.$$

**Exemplo 6:** Foi realizada uma entrevista com 1100 indivíduos para avaliar a opinião em relação a legalização do aborto. Os resultados, considerando o sexo do indivíduo, são apresentados na tabela a seguir.

Sexo	Favoráveis	Contrários	Totais
Fem	309	191	500
Mas	319	281	600
Totais	628	472	1100

$$(N_{11}, N_{12}, N_{21}) \sim \text{Multinomial}(1100, (p_{11}, p_{12}, p_{21}, p_{22}))$$

Para tabelas  $r \times c$  a verossimilhança é proporcional a

$$\prod_{i=1}^r \prod_{j=1}^c p_{ij}^{n_{ij}}$$

Os estimadores de máxima verossimilhança são:

$$\hat{p}_{ij} = \frac{N_{ij}}{n}$$

**Hipótese de independência:**

$$H_0 : p_{ij} = p_{i+} p_{+j} \quad i = 1, \dots, r, \quad j = 1, \dots, c$$

Sob  $H_0$  (independência) temos que

$$E[N_{ij}] = np_{ij} = np_{i+}p_{+j}$$

Substituindo  $p_{i+}$  e  $p_{+j}$  por suas estimativas, temos que o valor esperado na casela  $(i, j)$  é

$$e_{ij} = n \left( \frac{n_{i+}}{n} \right) \left( \frac{n_{+j}}{n} \right) = \frac{n_{i+}n_{+j}}{n}$$

A estatística Qui-quadrado de Pearson é dada por

$$Q_p = \sum_{i=1}^r \sum_{j=1}^c \frac{(n_{ij} - e_{ij})^2}{e_{ij}}$$

- Valores grandes de  $Q_p$  são indicativos contra  $H_0$  (independência). Portanto, indicam dependência entre as variáveis.
- Para amostras "grandes" a estatística  $Q_p$  tem distribuição Qui-quadrado com  $\nu = (r - 1)(c - 1)$  graus de liberdade
- A região crítica do teste é dada por  $RC = \{Q_p > \chi_{\alpha, \nu}^2\}$
- No exemplo 3 temos  $Q_p = 8.3$ . Para  $\alpha = 0.05$  e  $\nu = 1$  temos  $\chi_{0.05, 1}^2 = 3.84$ .
- Rejeita-se a independência entre Sexo e Opinião sobre o aborto (valor-P < 0.004)

- 1 Para cada um dos exemplos apresentados aqui, estabelecer o tipo de estudo (se possível) e o modelo probabilístico associado
- 2 Estudar e fazer os exercícios dos capítulos 1 e 2 do livro da Suely Giolo.