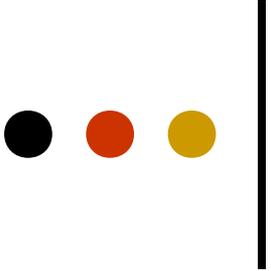




Pensamento crítico

2011/12

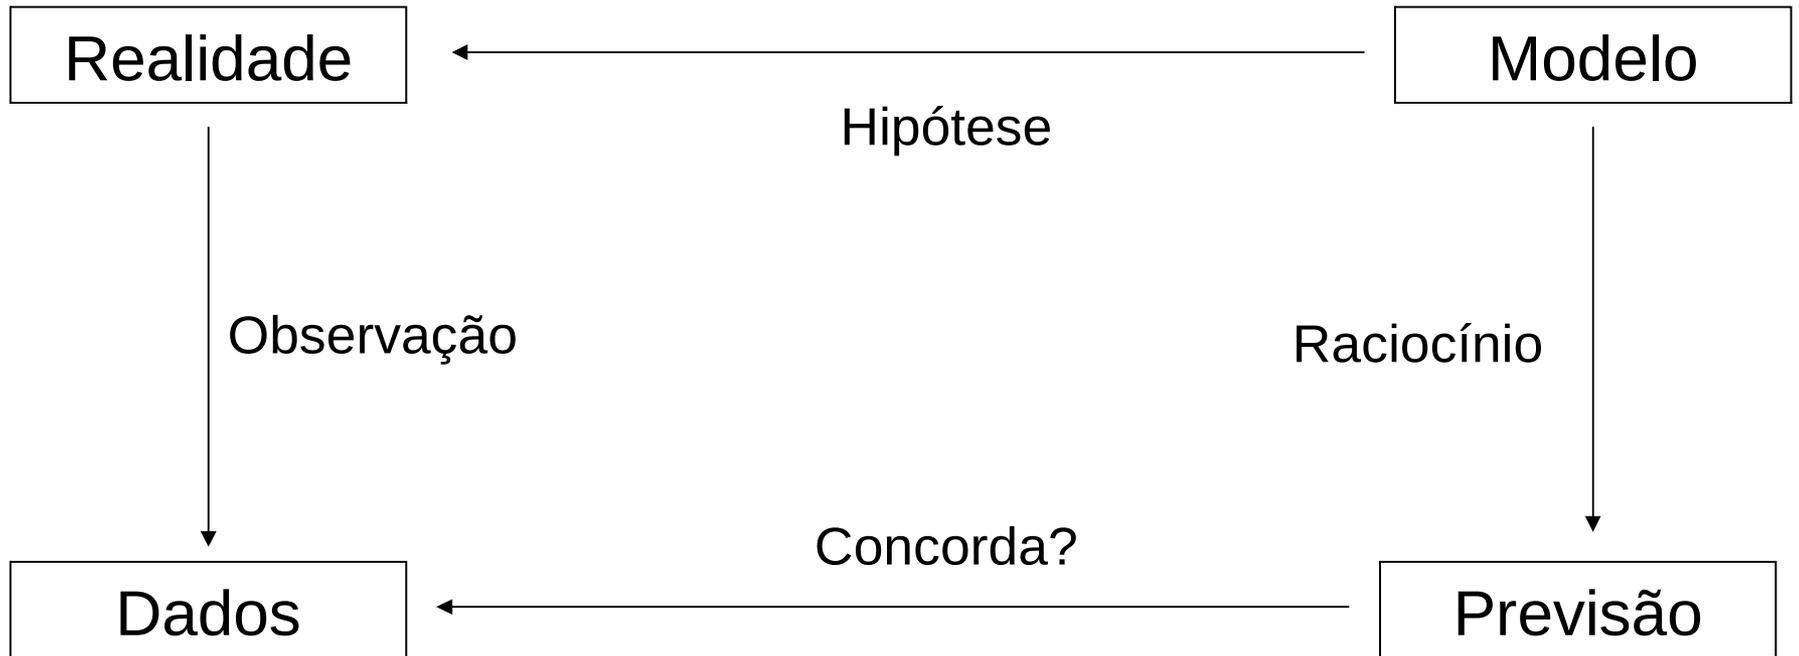
Aula 8, 2 e 4-11-11



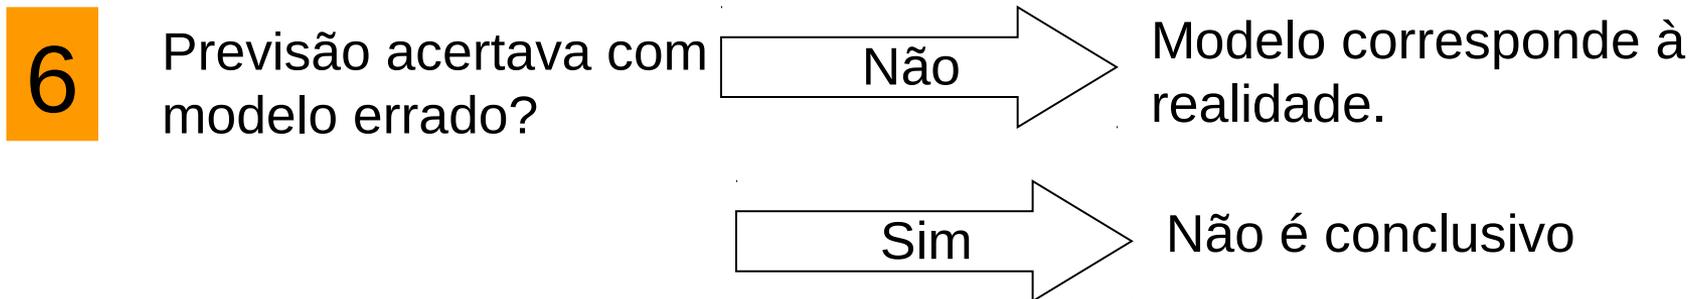
Resumo

- Experiências cruciais
- Ciência Marginal
- Modelos Estatísticos
 - Desenvolvimento de modelos
- Modelos Causais

Modelos Teóricos

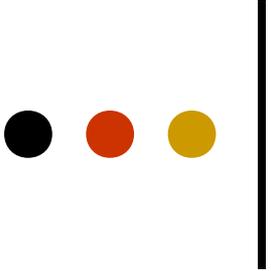


Como avaliar



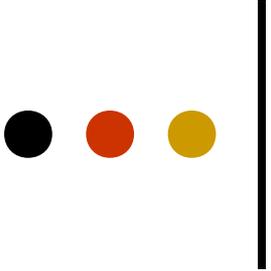


Experiência Crucial



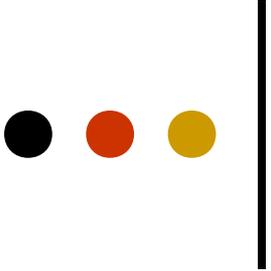
Experiência Crucial

- Dados 2 modelos
 - Experiência tal que os dados possíveis (ou a amostra) só pode ser compatível com um dos modelos.



Experiência Crucial

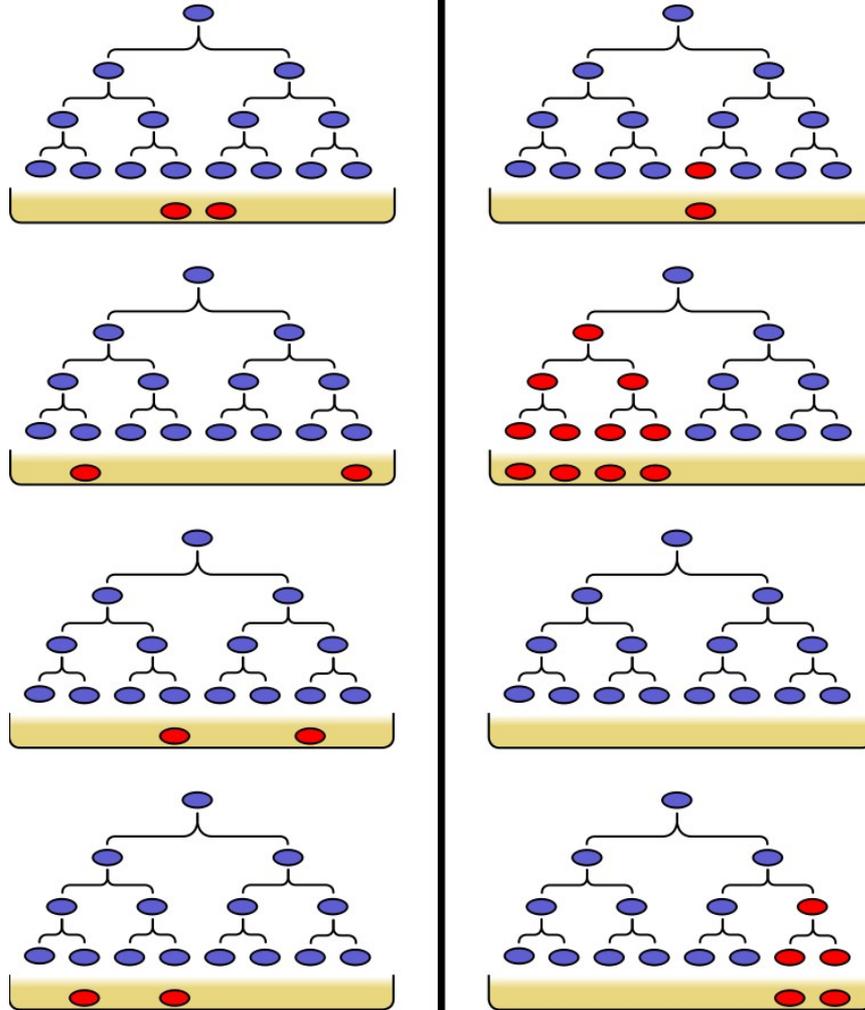
- Mutações
 - Um vírus ao qual uma espécie de bactéria é susceptível.
 - Algumas são resistentes e sobrevivem graças a uma mutação.
 - A mutação surgiu por acaso ou foi induzida pelo vírus?

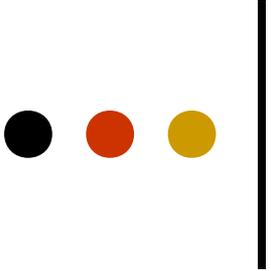


Experiência Crucial

- Experiência
 - Salvador Luria e Max Delbrück prepararam 20 culturas de bactérias
 - Depois de um tempo, plaquearam em agar com o vírus
 - Se mutação induzida, o número de resistentes seria aproximadamente igual
 - Se mutação aleatória, o número dependeria de quando a mutação tinha surgido e seria muito variável

Experiência Crucial



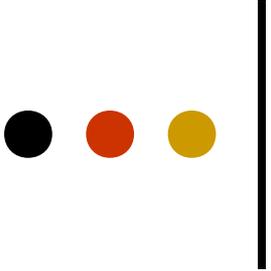


Experiência Crucial

- Experiência
 - Salvador Luria e Max Delbrück cultivaram 20 caixas de bactérias
 - Inocularam com o vírus
 - O número de resistentes era muito variável entre as caixas
 - Ou seja, a experiência permitiu decidir entre os dois modelos alternativos.

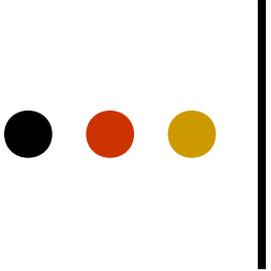


Ciência Marginal



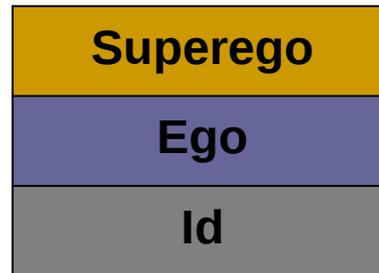
Ciência Marginal

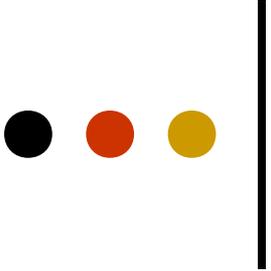
- A investigação é científica se
 - Propõe modelos de algum aspecto da realidade.
 - Os modelos podem ser confrontados com os dados.
 - Os modelos são ajustados de forma progressiva.
- Mas pode ser inconclusiva e ficar à margem.
 - Ou, se persistir em se desviar do confronto, acabar por se tornar regressiva e deixar de ser ciência.



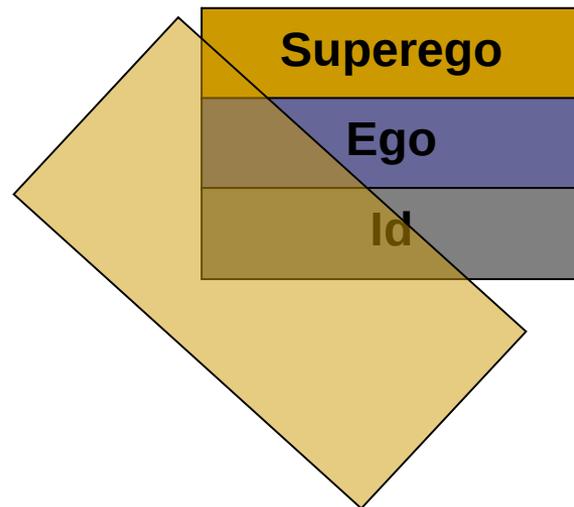
Ciência Marginal

- Exemplo: “Teoria” (modelo) de Freud

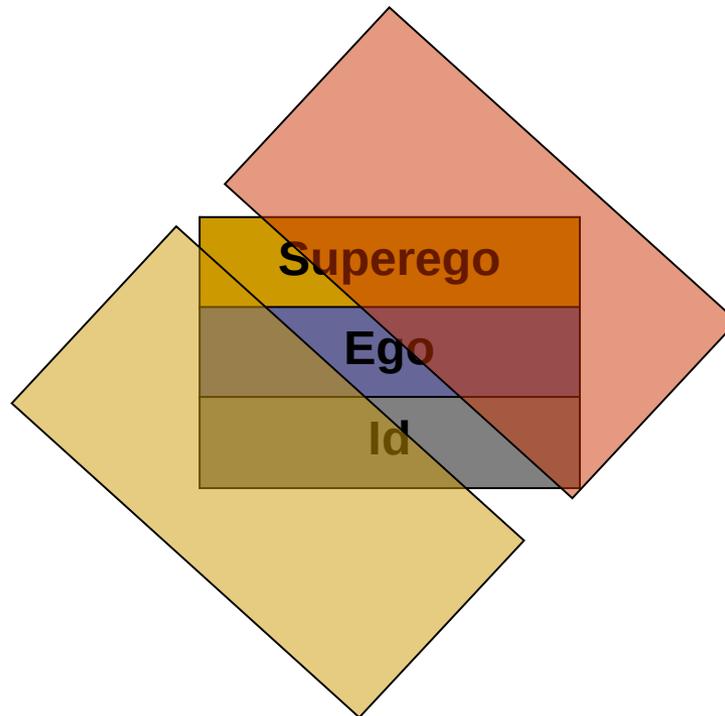




Ciência Marginal

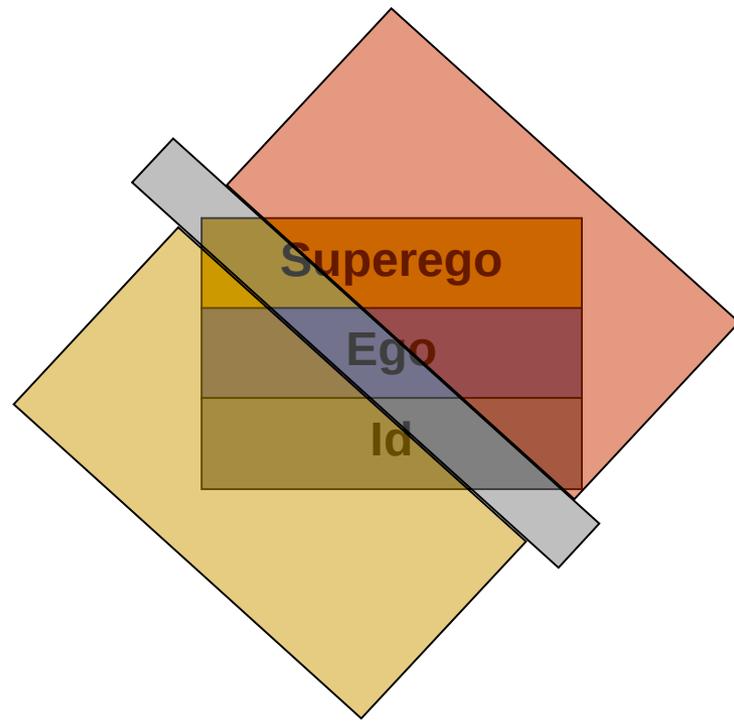


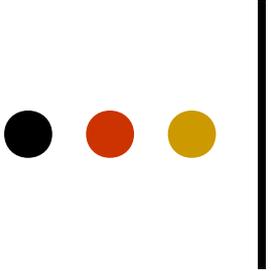
Ciência Marginal





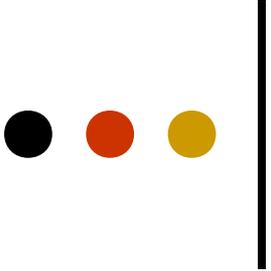
Ciência Marginal





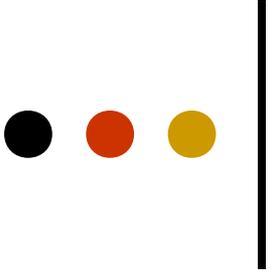
Ciência Marginal

- Hans tinha 4 anos e muito medo de cavalos. Especialmente das palas e arreios (cabeçadas).
- Antes dormia com a mãe, mas agora o pai queria que ele dormisse no quarto dele.
- Passava mais tempo com a ama e foi com esta, no parque, que se assustou com um cavalo.



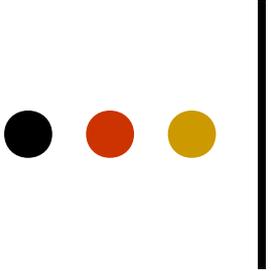
Ciência Marginal

- Freud propôs
 - Crise de Édipo: o Id de Hans queria a atenção da mãe.
 - O Ego de Hans tinha medo que o pai se zangasse.
 - O superego tinha sido ensinado que se devia amar os pais e por isso forçava a projecção do medo do pai num medo de cavalos.
 - Os arreios e palas eram a barba e óculos do pai.



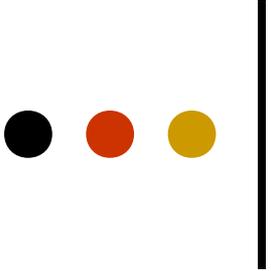
Ciência Marginal

- Freud disse ao pai de Hans para lhe assegurar que não estava zangado com o miúdo.
- Ao fim de uns tempos o medo de cavalos foi diminuindo



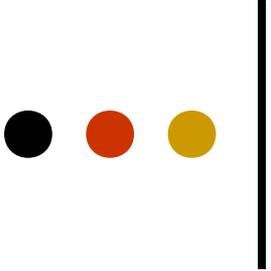
Ciência Marginal

- 1: Realidade
 - O medo do pequeno Hans
- 2: Modelo
 - O conflito entre os desejos do Id, o medo do Ego e os preceitos do Superego levaram a projectar o medo do pai nos cavalos.
 - O problema está nos aspectos sub-conscientes.



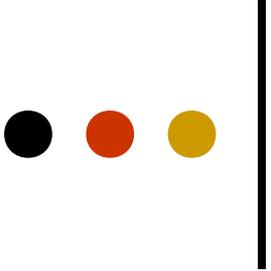
Ciência Marginal

- 3: Previsão
 - O modelo diz que tomar consciência destes factores ajuda a resolver o problema.
- 4: Dados
 - Hans ficou melhor com o tratamento.



Ciência Marginal

- 5: Inconsistência?
 - Não.
- 6: Acertava mesmo estando errado?
 - Mesmo sem outro modelo explícito podemos pensar noutras explicações. A criança apanhou um susto e passou-lhe, ou queria atenção da mãe e estava a fazer fita, etc...

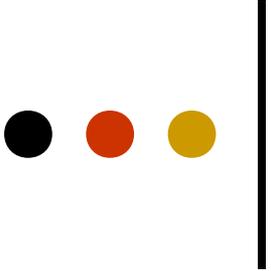


Ciência Marginal

- Resumindo:
 - O modelo é testável, em princípio, mas os dados são inconclusivos.
 - Daqui pode progredir se mais dados ajudarem a rejeitar ou confirmar o modelo (rejeitando alternativas)
 - Ou regredir se o modelo for demasiado permissivo, eventualmente deixando de ser ciência.

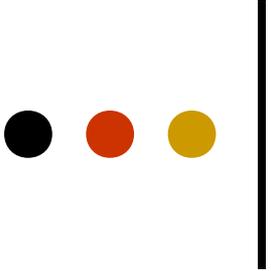


Modelos Estadísticos



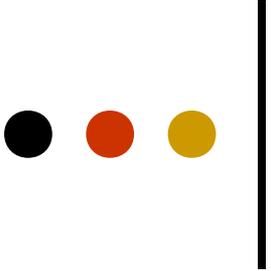
Modelos Estatísticos

- Um modelo estatístico é um caso particular do modelo teórico
 - O aspecto da realidade é uma população, que pode ser de indivíduos, ocorrências, etc
 - Os dados são uma amostra da população
 - O modelo é acerca da distribuição de características na população
 - De onde se infere o que se espera da amostra, com uma margem de erro



Modelos Estatísticos

- Estudar uma população por amostragem.
 - Relação entre escolaridade e rendimento.
 - Colesterol é factor de risco para ataques cardíacos?

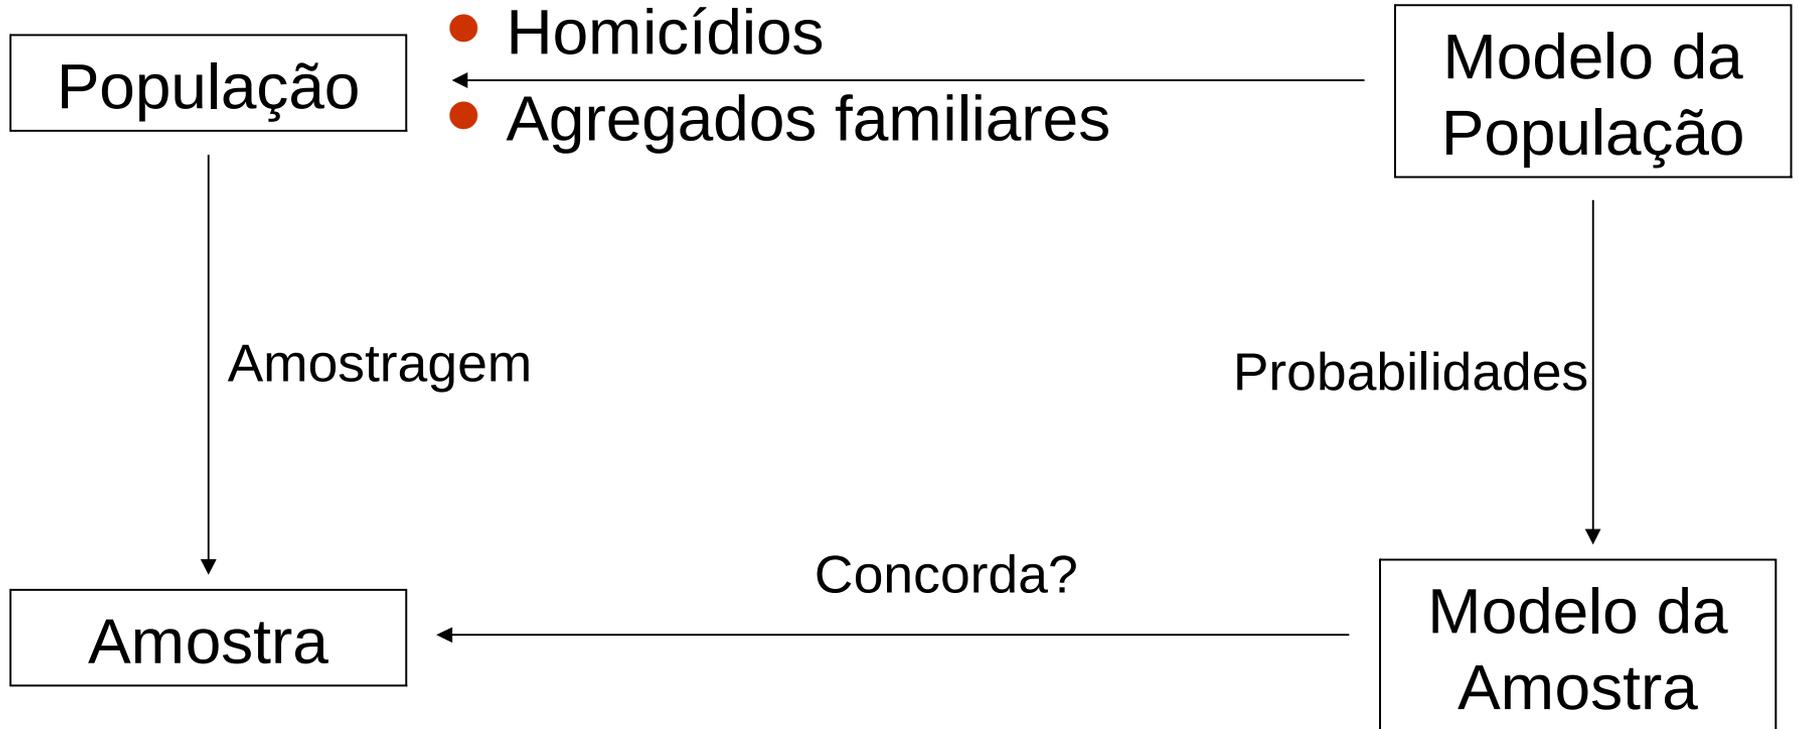


Modelos Estatísticos

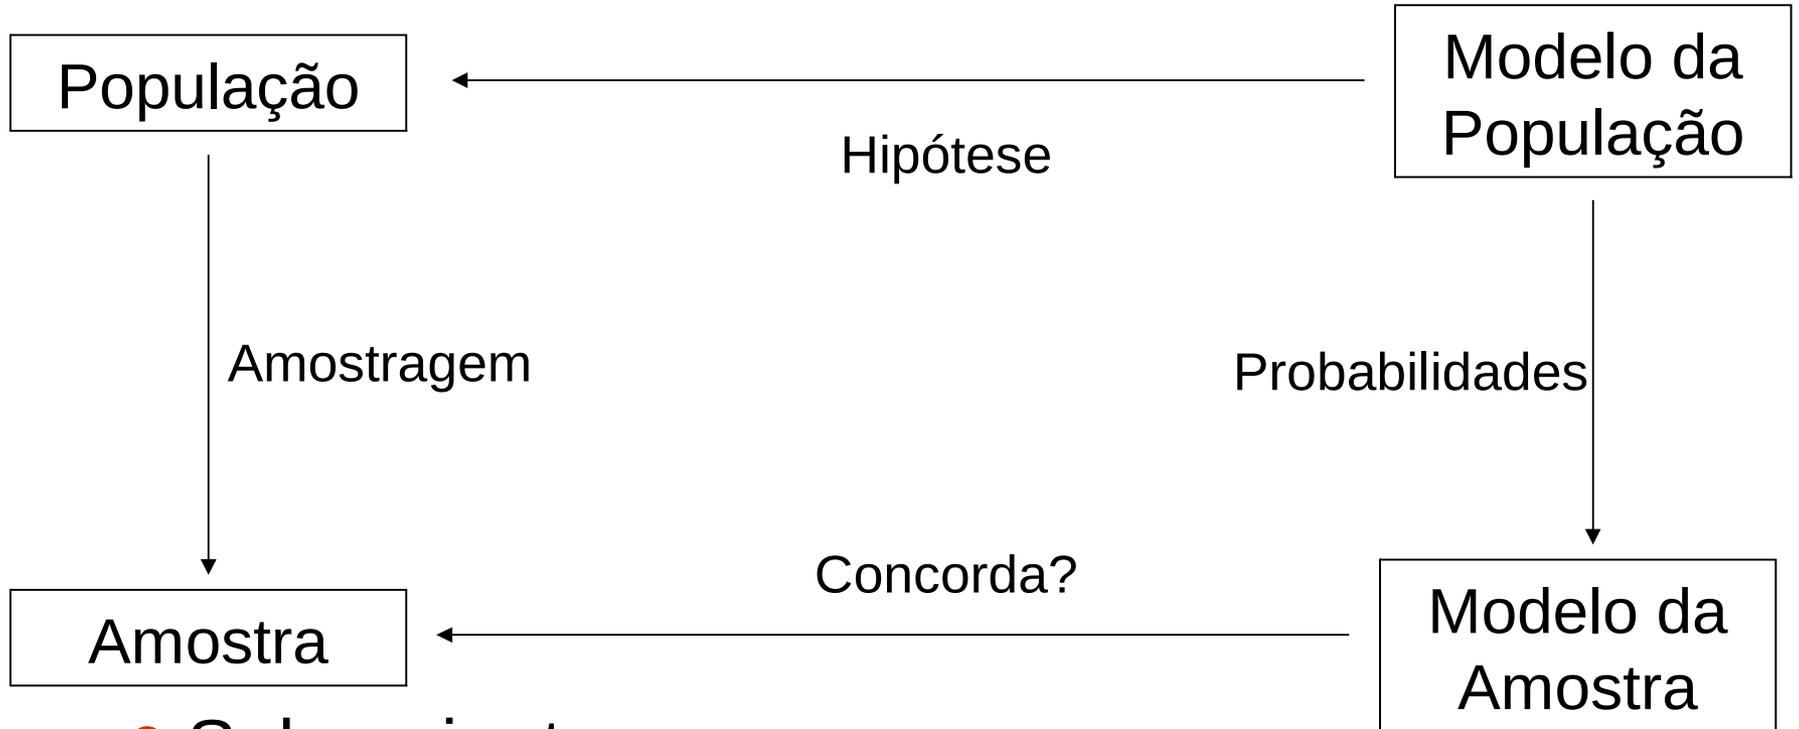
- Estudar uma população por amostragem.
 - Relação entre escolaridade e rendimento.
 - Colesterol é factor de risco para ataques cardíacos?
- Probabilidades.
 - A hipótese do modelo corresponder à população é avaliada pela probabilidade da amostra dado o modelo.
 - Atenção: não é a probabilidade do modelo!

Modelos Estatísticos

- Adultos <50 anos
- Homicídios
- Agregados familiares



Modelos Estatísticos

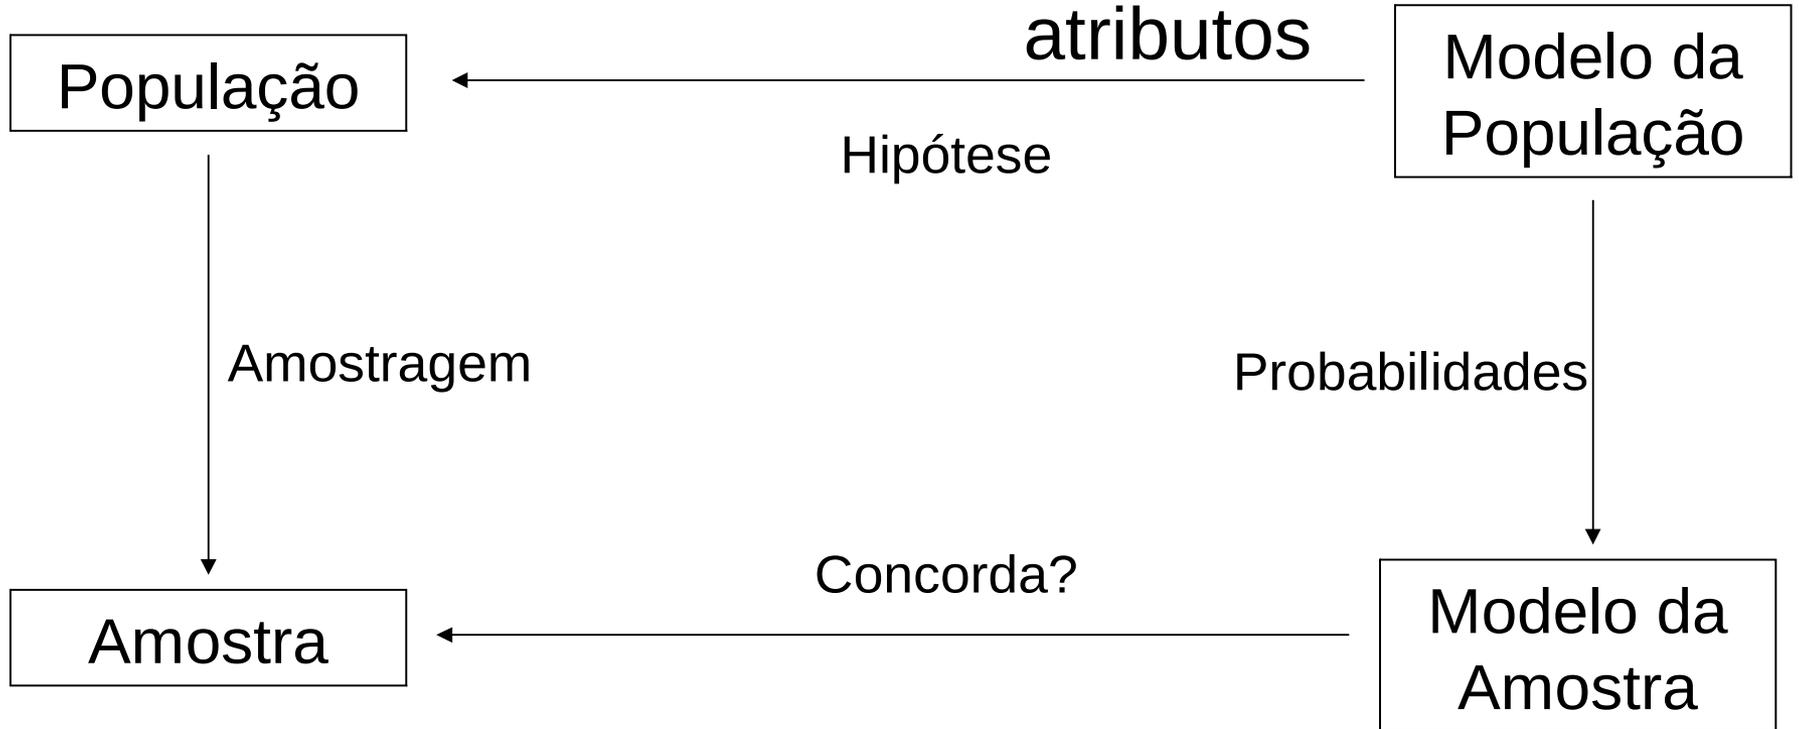


- **Subconjunto**

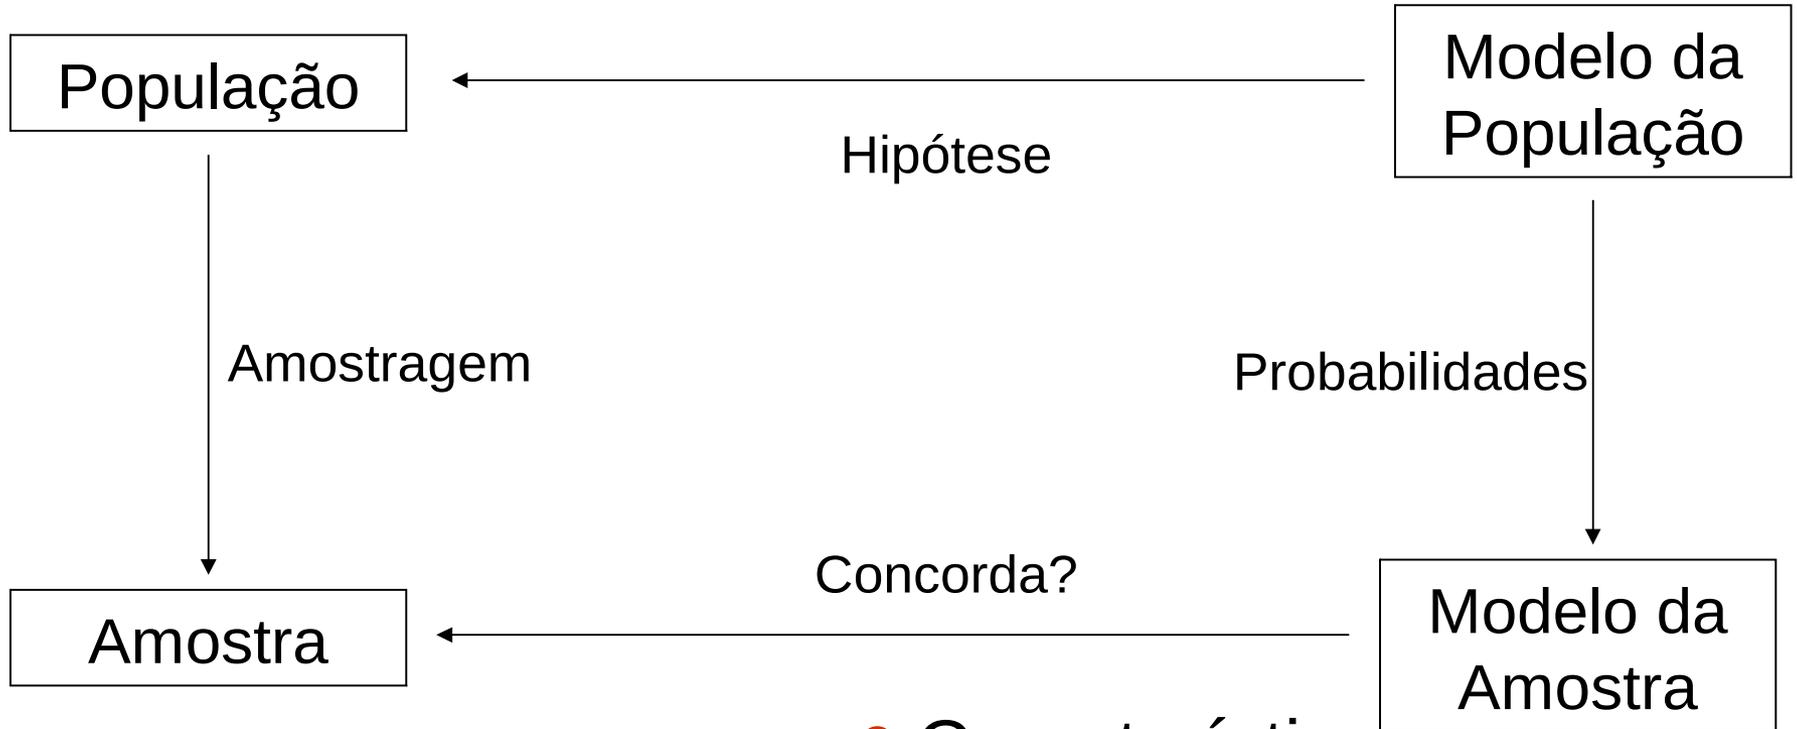
- Representativo (?)

Modelos Estatísticos

- Distribuição de atributos



Modelos Estatísticos



- Características esperadas
 - Probabilidade

Modelos Estatísticos

- 50% vermelhos
- 50% brancos

População

Modelo da População

- Saco com berlindes vermelhos e brancos.

Hipótese

Amostragem

Probabilidades

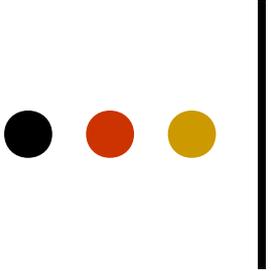
Amostra

Modelo da Amostra

Concorda?

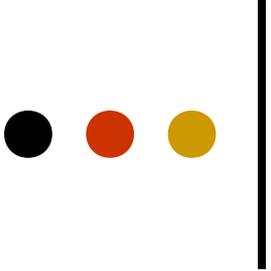
- 5 Berlindes
 - 3 vermelhos
 - 2 brancos

• ?



Probabilidades

- Variável aleatória
 - Atributo que pode tomar vários valores
 - E.g. Cor
- Probabilidade
 - Proporção do valor (ou combinação de valores) na população.
 - $P(V)=0.5$



Probabilidades

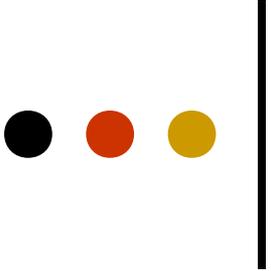
- Modelo 1

- Cor:

- B 0.70
- V 0.30

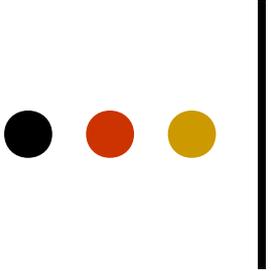
- Tamanho

- L 0.50
- S 0.50



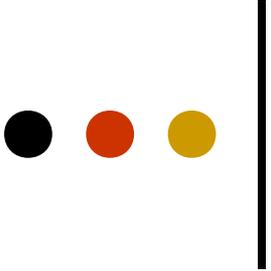
Probabilidades

- Conjunção
 - Se as variáveis são independentes a probabilidade de $V1=X$ e $V2=Y$ é $P(X)*P(Y)$.
- Exemplo
 - $P(B \text{ e } L)=0.7*0.5=0.35$



Probabilidades

- Disjunção
 - Se os valores são mutuamente exclusivos, a probabilidade de ser um ou outro é a soma das probabilidades
- Exemplo
 - $P(B \text{ ou } V) = 0.7 + 0.3 = 1$
 - $P(2 \text{ ou } 3 \text{ num dado de } 6) = 1/6 + 1/6 = 1/3$



Probabilidades

- Modelo A

Cor:

B 0.50

V 0.50

Tamanho:

0.25 S, 0.25 L

0.25 S, 0.25 L

- Modelo B

Cor:

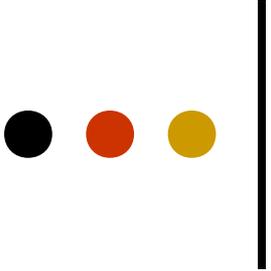
B 0.50

V 0.50

Tamanho:

0.10 S, 0.40 L

0.40 S, 0.10 L



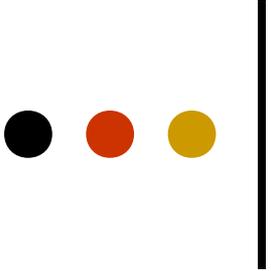
Probabilidades

- Correlação
- Modelo A

S	S
L	L

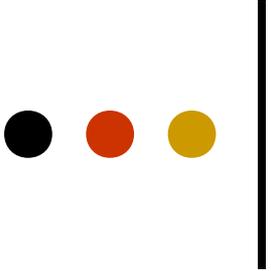
Modelo B

S	S
L	



Probabilidades

- Conjunção
 - Se as variáveis não são independentes a probabilidade de $V1=X$ e $V2=Y$ é $P(X)*P(Y/X)$.
 - $P(Y/X)$ é $P(Y)$ sabendo que $V1=X$ (probabilidade condicionada)
- Exemplo (modelo B)
 - $P(B \text{ e } L)=0.5*P(L/B)=0.5*0.8=0.4$



Probabilidades

- Disjunção
 - Se os valores não são mutuamente exclusivos, a probabilidade de ser um ou outro é a soma das probabilidades menos a probabilidade de ser ambos
- Exemplo
 - $P(B \text{ ou } L) = 0.5 + 0.5 - P(B \text{ e } L) = 1.0 - 0.4$

Modelos Estatísticos

- 50% vermelhos
- 50% brancos

População

- Saco com berlindes vermelhos e brancos.

Modelo da População

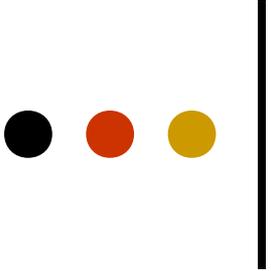
Hipótese:
Bom ajuste?

Modelo da Amostra

Amostra

- 5 Berlindes
 - 3 vermelhos
 - 2 brancos

• ?

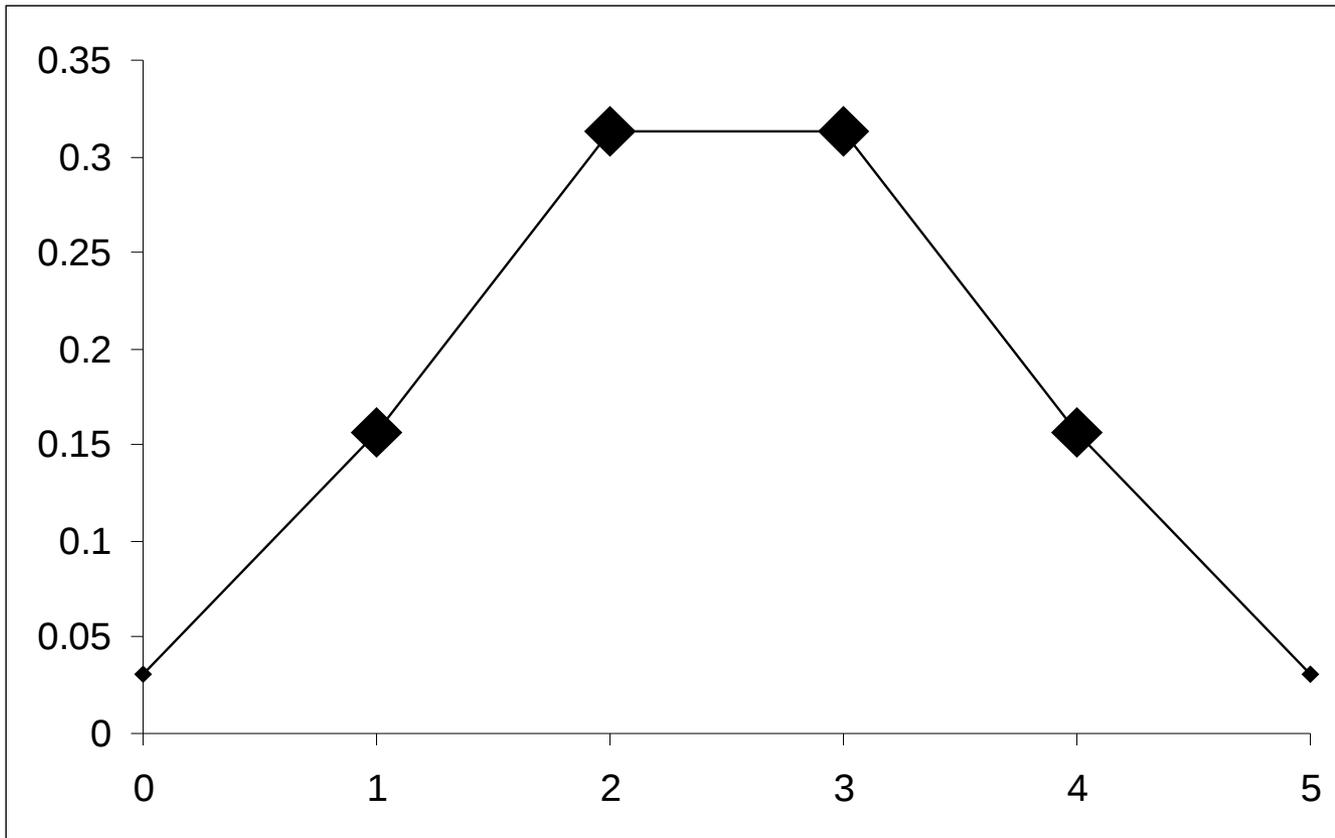


Probabilidades

- $P(0 V) = 1/2 * 1/2 * 1/2 * 1/2 * 1/2 = 1/32$
- $P(1 V) = 5 * 1/32 = 0,156$
- $P(2 V) = 5 * 4 / 2 * 1/32 = 0,312$
- $P(3 V) = P(2 B) = P(2 V) = 0,312$
- ...

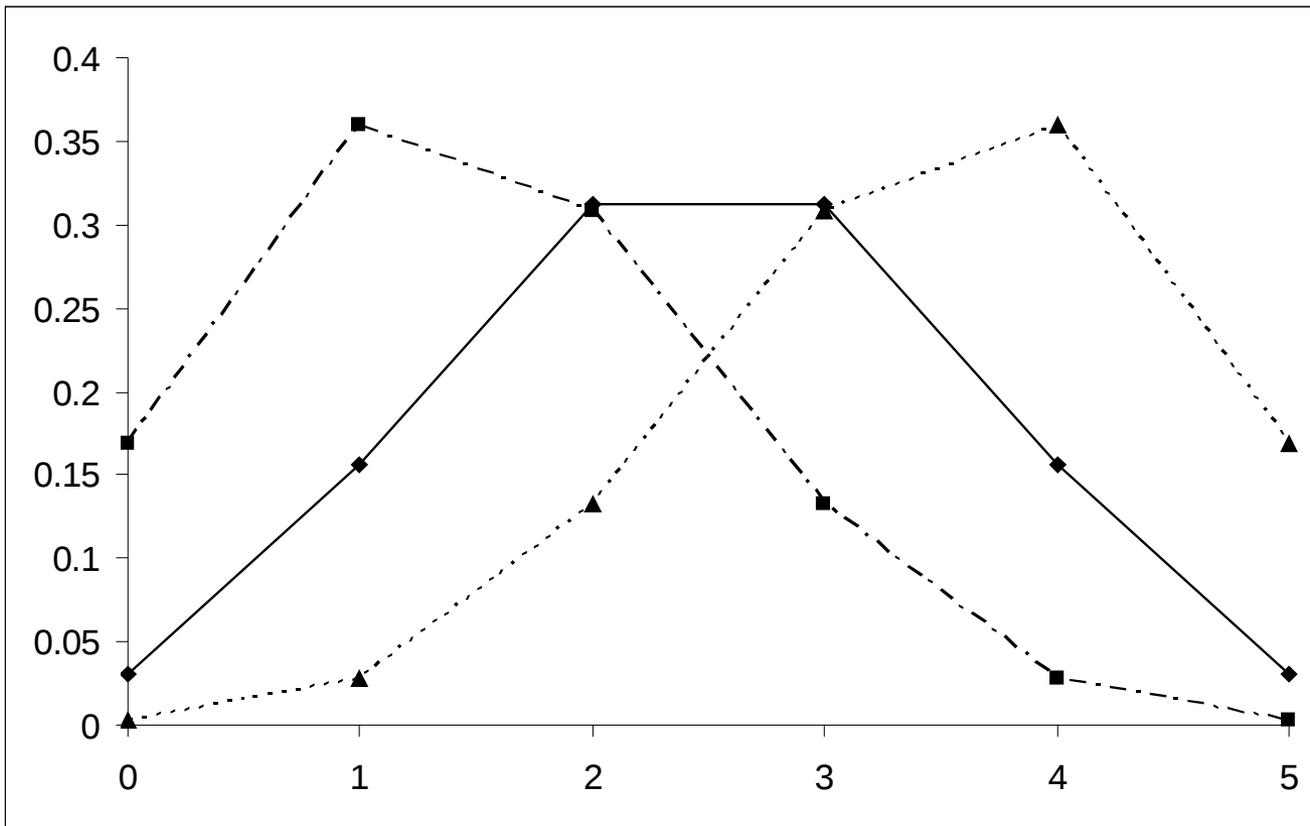
Modelos Estadísticos

- 5 berlindes:



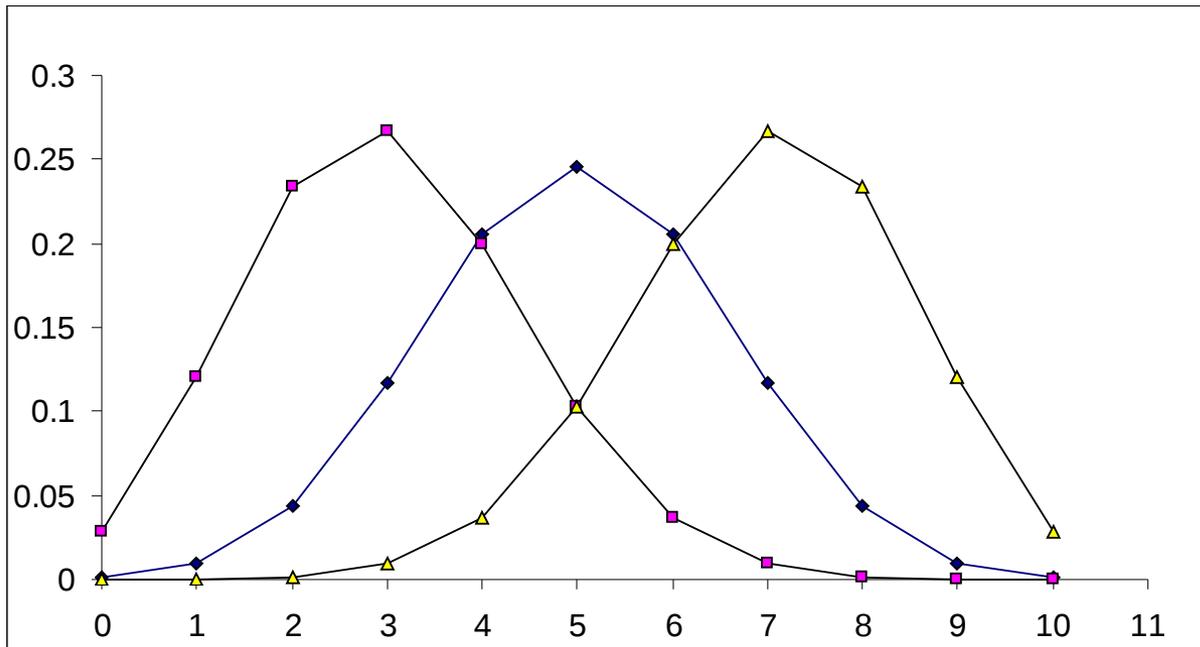
Modelos Estadísticos

- 5 berlindes:



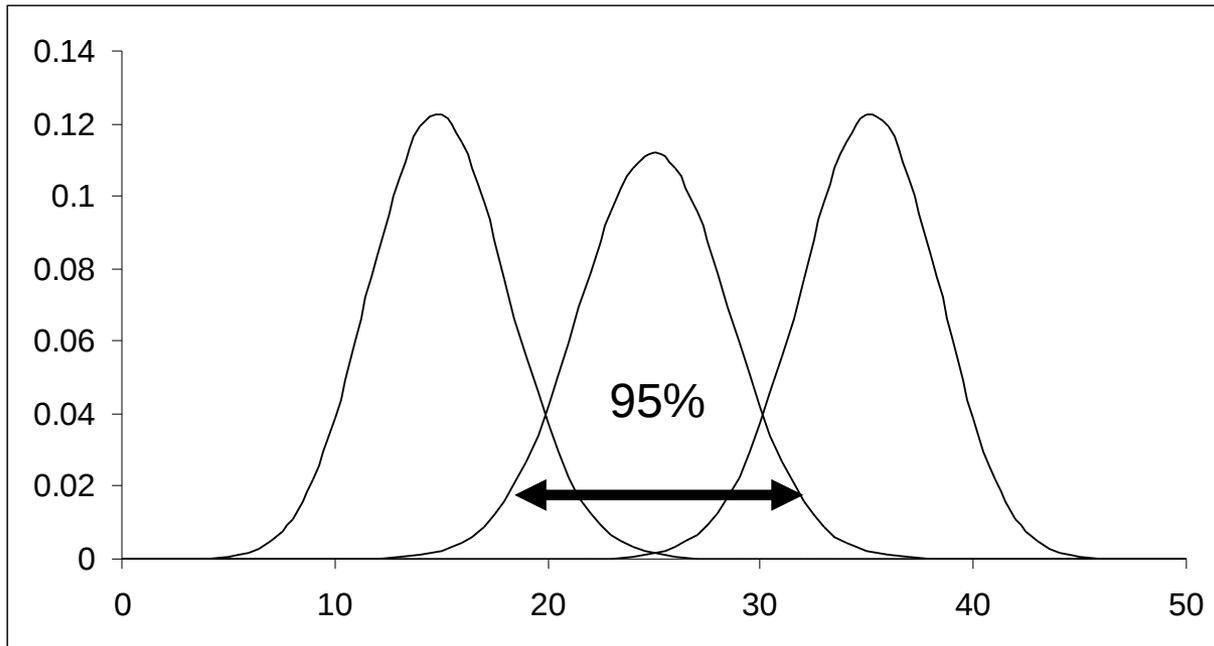
Modelos Estadísticos

- 10 berlindes:



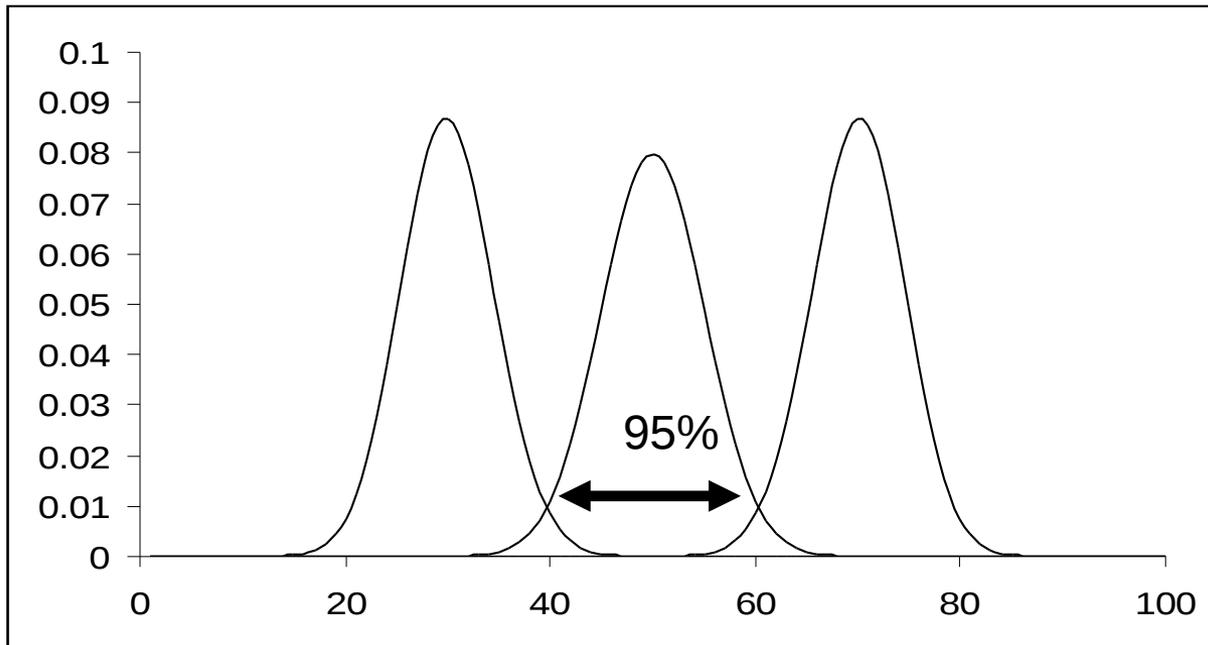
Modelos Estadísticos

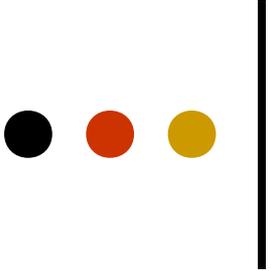
- 50 berlindes:



Modelos Estadísticos

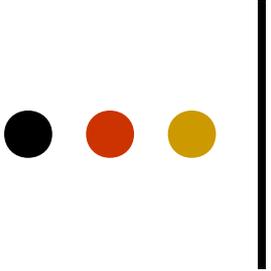
- 100 berlindes:





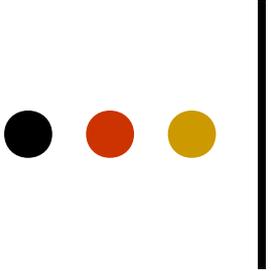
Amostra

- Tamanho da amostra
 - Amostras maiores permitem discriminar melhor entre distribuições (modelos) alternativos.



Modelos Estatísticos

- Quanto maior a amostra menor a margem de erro para um valor de confiança.
- Quanto maior a confiança, maior a margem de erro:
 - 60%: 1 desvio padrão
 - **95%: 2 desvios padrão**



Modelos Estatísticos

- Confiança

- Probabilidade da estatística da amostra dentro daquele intervalo **se o modelo corresponder à população.**
- Se a amostra sai fora de um intervalo de confiança de 95%, é pouco plausível que o modelo esteja correcto.
- Nota: não é a probabilidade do modelo estar correcto.
 - A correspondência entre modelo e população não é uma variável aleatória.

Modelos Estatísticos

- 50% vermelhos
- 50% brancos

População

Modelo da População

Hipótese

- Saco com berlindes vermelhos e brancos.

Amostragem

Probabilidades

Concorda?

Amostra

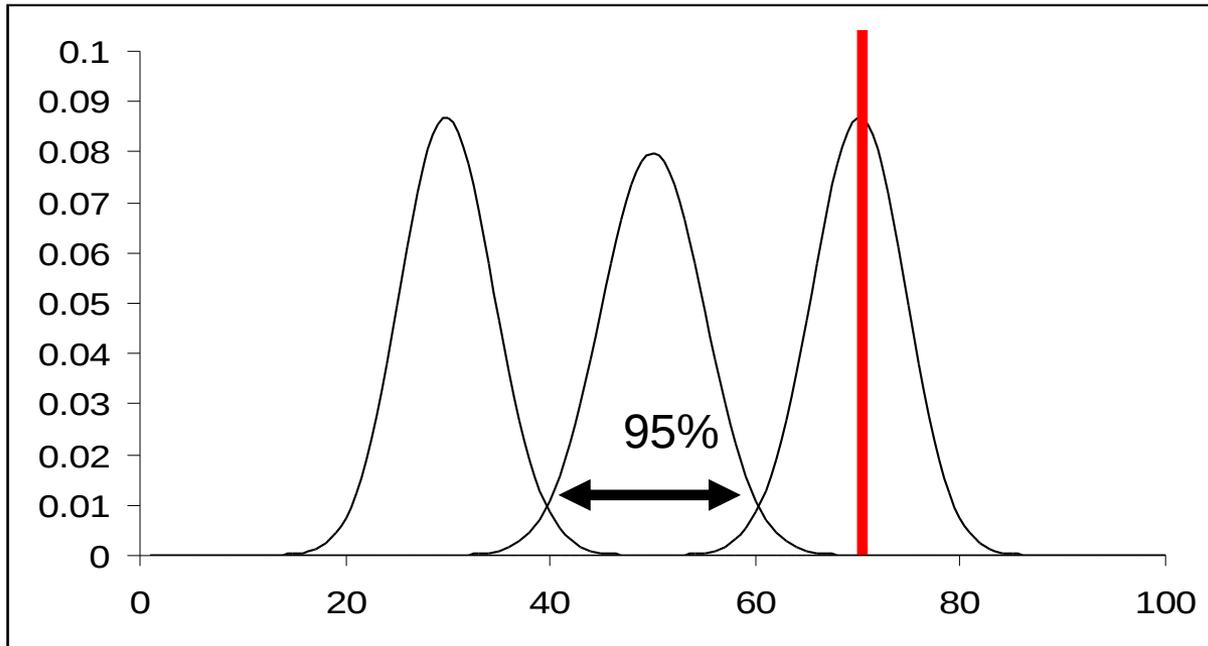
Modelo da Amostra

- 100 Berlindes
 - 70 vermelhos
 - 30 brancos

• 50 ± 10

Modelos Estadísticos

- 100 berlindes:



Modelos Estatísticos

- 50% vermelhos
- 50% brancos

População

Modelo da População

- Saco com berlindes vermelhos e brancos.

Hipótese

Amostragem

Probabilidades

Amostra

Concorda?

Modelo da Amostra

- 100 Berlindes
 - 70 vermelhos
 - 30 brancos

- 50 ± 10
- Modelo rejeitado

Modelos Estatísticos

- 70% vermelhos
- 30% brancos

População

Modelo da População

Hipótese

- Saco com berlindes vermelhos e brancos.

Amostragem

Probabilidades

Concorda?

Amostra

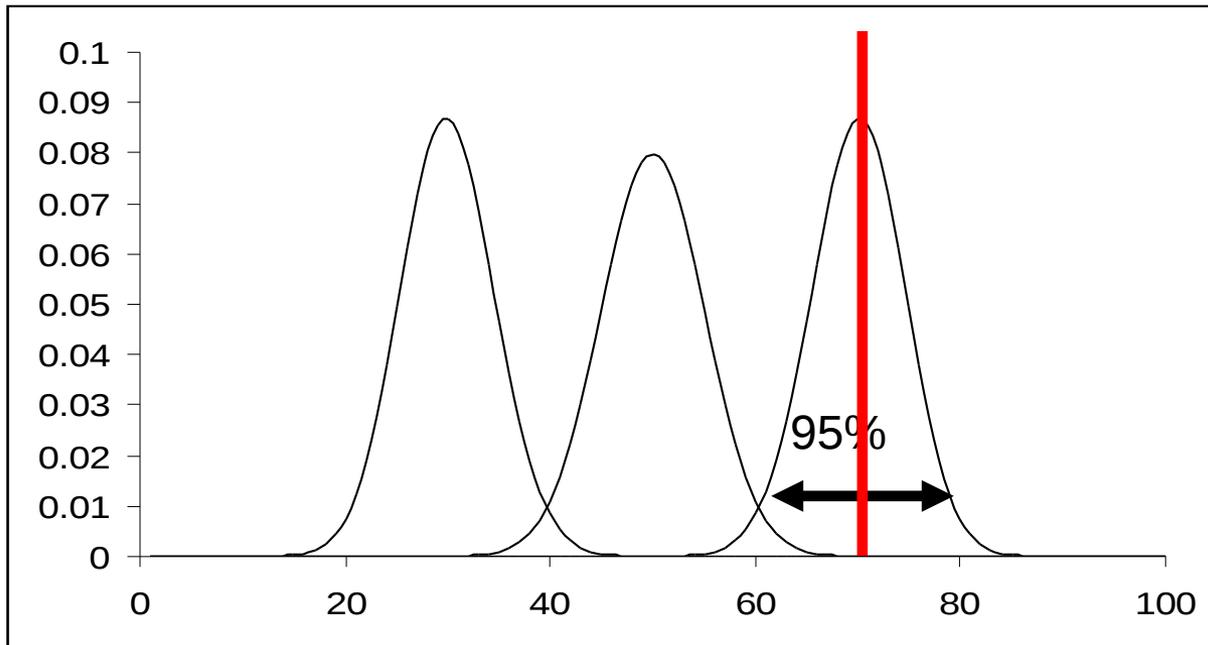
Modelo da Amostra

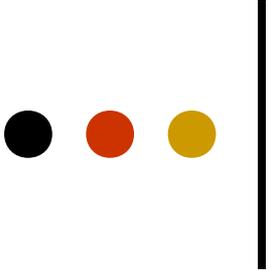
- 100 Berlindes
 - 70 vermelhos
 - 30 brancos

- 70 ± 10
- 30 ± 10
- Não rejeitado
- Acertaria mesmo errado?

Modelos Estatísticos

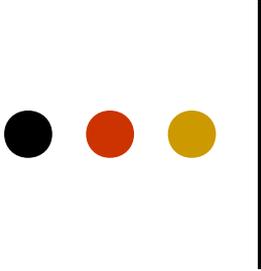
- Modelos que não rejeitaríamos.





Modelos Estatísticos

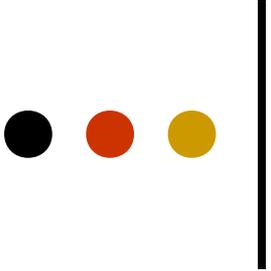
- Dada a distribuição, amostras vão cair 95% das vezes dentro da margem de erro.
- Portanto, dada uma amostra:
 - Podemos **estimar** o valor na população a partir do valor da amostra.
 - Esse valor será o da amostra +- a **margem de erro**.
 - O intervalo corresponde ao conjunto de modelos que não podemos rejeitar.
- 60-80% V; 40-20% B



Modelos Estatísticos

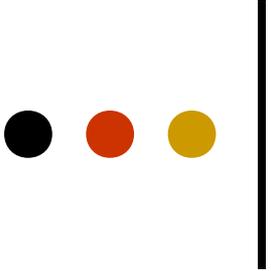
- Em rigor, o cálculo é mais complexo
 - Depende das funções de distribuição
 - Mas aqui usamos margens de erro aproximadas

Amostra	Erro
25	$\pm .25$
100	$\pm .10$
500	$\pm .05$
2000	$\pm .02$
10000	$\pm .01$



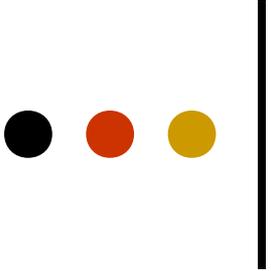
Desenvolvimento

- Quando os dados são inconsistentes com uma versão do modelo, ou não o suportam devidamente.
- Mas uma alteração ao modelo resolve o problema
- 1,2,3,4,5 -> inconsistente
- 1,2,3,4,5,6.
 - 50% B e V -> 70% V 30% B
- (Mas é preciso continuar o processo)



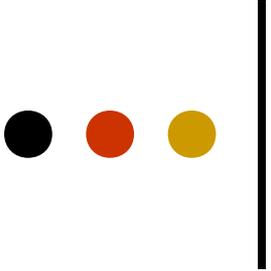
Modelos Estatísticos

- Comparação de distribuições
 - Duas amostras correspondem a duas distribuições diferentes se não há um modelo aceitável consistente com ambas.
 - Se há um modelo consistente com ambas não podemos dizer que venham de distribuições diferentes.



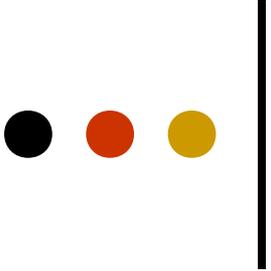
Modelos Estatísticos

- Exemplo: não distintas
 - Saco 1, 100, 0.6 V (ME 0.10)
 - Saco 2, 50, 0.8 V (ME 0.15)
 - Modelo 0.7 V é consistente com ambos
 - 0.6 ± 0.1
 - 0.8 ± 0.15
 - Os intervalos intersectam-se



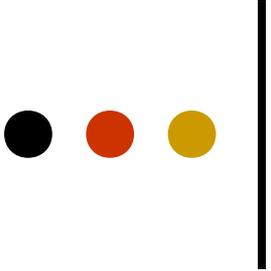
Modelos Estatísticos

- Exemplo: distintas
 - Saco 1, 500, 0.6 V (ME 0.05)
 - Saco 2, 500, 0.8 V (ME 0.05)
 - Nenhum modelo é consistente com ambas
 - 0.6 ± 0.05
 - 0.8 ± 0.05
 - Os intervalos são disjuntos



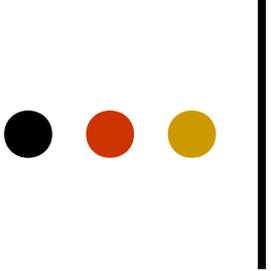
Modelos Estatísticos

- Correlação
 - O valor de uma variável afecta a distribuição de outra.
 - A correlação é simétrica.



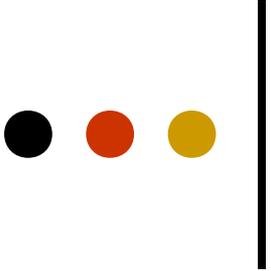
Modelos Estatísticos

- Correlação, exemplo:
 - Amostra de 600 berlindes
 - 500 vermelhos
 - 325 são grandes
 - 100 de outras cores
 - 35 são grandes
 - $P(L/V) = 0.65 \pm 0.05$ ($n=500$)
 - $P(L/\sim V) = 0.35 \pm 0.10$ ($n=100$)
 - Há correlação:
 - as populações V e $\sim V$ são distintas.



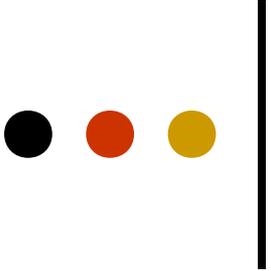
Avaliar Modelos Estatísticos

- 1: População
 - Identificar a população de interesse. Notar possível discrepância entre esta e a população amostrada.
- 2: Os dados na amostra
 - Identificar a amostra e os dados relevantes nesta.
- 3: O modelo estatístico
 - Explicitar o modelo (Correlação? Distribuição? Diferenças?)



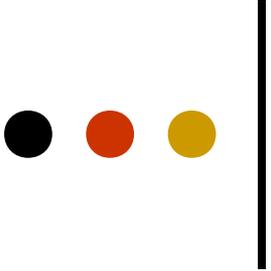
Avaliar Modelos Estatísticos

- 4: Amostragem Aleatória
 - Avaliar o processo de amostragem:
 - A probabilidade de cada elemento ser seleccionado é igual para todos (a probabilidade de seleccionar um valor é igual à fracção na população)
 - Não há correlação entre as escolhas para a amostra



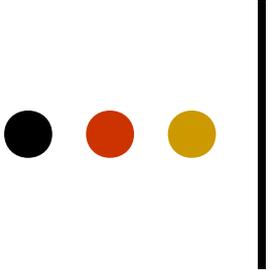
Avaliar Modelos Estatísticos

- 5: Avaliar a hipótese
 - O modelo é adequado aos dados?
 - É consistente?
 - Há evidência de correlação ou de diferença entre distribuições (se for esse o modelo)?
 - Forte ou fraca?
- 6: Resumo da avaliação
 - Notar os factores principais (amostra, significância, etc).



Modelo estatístico

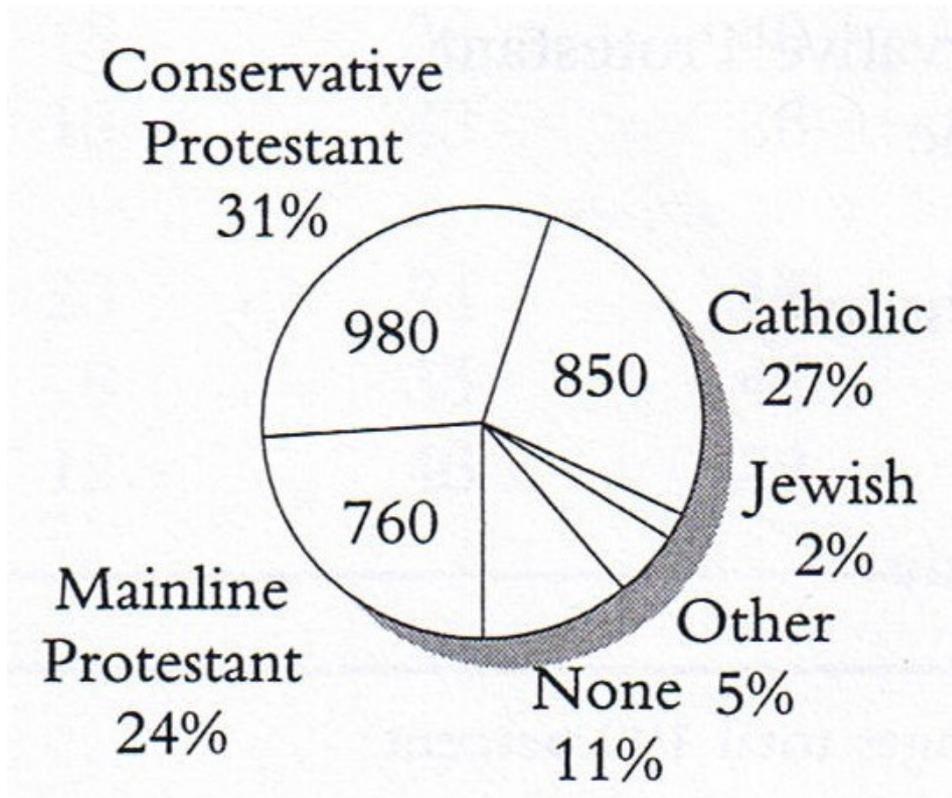
- National Health and Social Life Survey (NHSLs) 1992
 - 3000 adultos (18-49)
 - Entrevistas



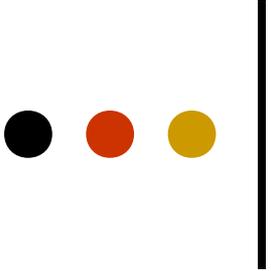
Modelo estatístico

- Zero parceiros nos últimos 12 meses
 - Católicos: 12%
 - Protestantes Conservadores: 13%
 - Judeus: 3%
- Há diferenças?

Modelo estatístico



- Com zero parceiros:
 - Católicos 12%
 - Protestantes 13%
 - Judeus 3%
- Amostra:
 - Católicos 1000
 - Protestantes 1000
 - Judeus 50



Modelo estatístico

25	$\pm .25$
100	$\pm .10$
500	$\pm .05$
2000	$\pm .02$
10000	$\pm .01$

·Com zero parceiros:

·Católicos 12%

·Protestantes 13%

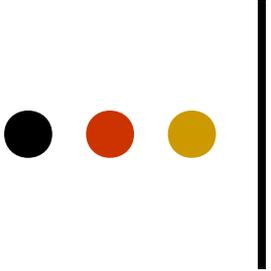
·Judeus 3%

·Amostra:

·Católicos 1000

·Protestantes 1000

·Judeus 50



Modelo estatístico

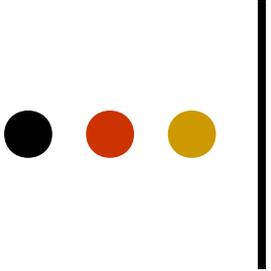
- Zero parceiros nos últimos 12 meses
 - Católicos: $12 \pm 3\%$
 - Protestantes: $13 \pm 3\%$
 - Judeus: $3 \pm 20\%$
- Não há diferença

Modelo estadístico

TABLE 6.4

SEX PARTNERS PAST TWELVE MONTHS

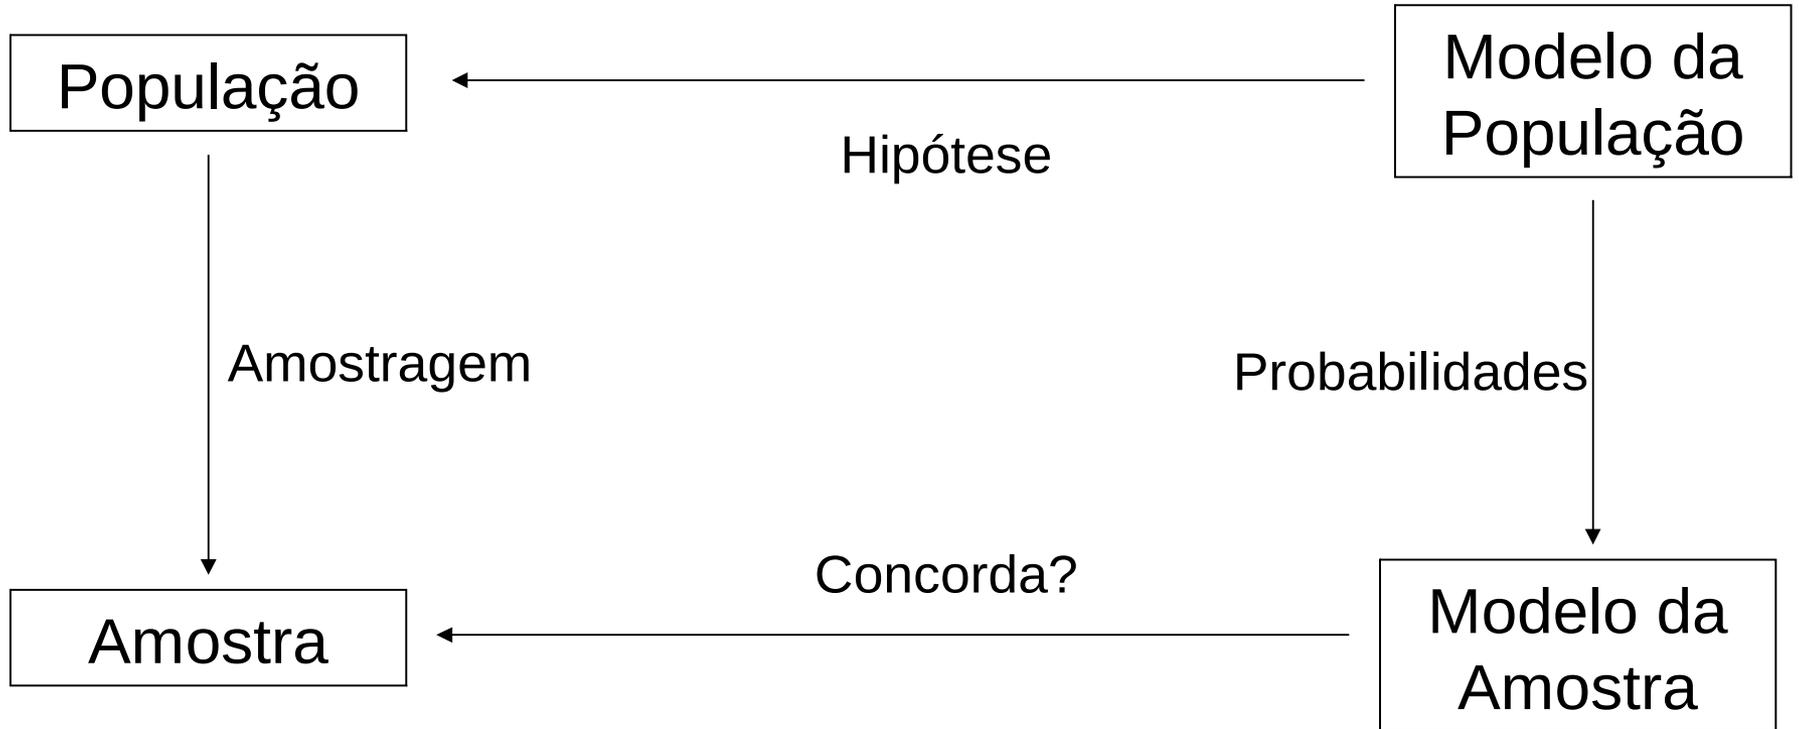
	0	1	2 TO 4	5+
Total	12%	71%	14%	3%
Gender				
Men	10	67	18	5
Women	14	74	10	2

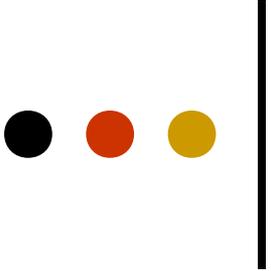


Modelo estatístico

- Mais que 1 parceiro nos últimos 12 meses? ($\pm 2\%$)
- Homens: $23 \pm 2\%$
- Mulheres: $12 \pm 2\%$
- Há diferença

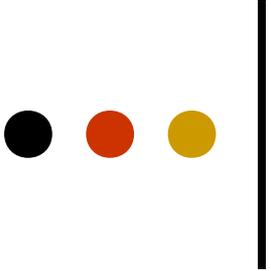
Modelo estatístico





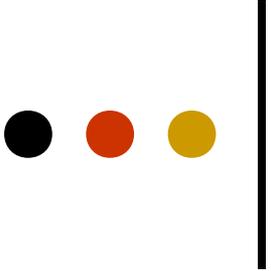
Modelo estatístico

- 1: Qual a população no mundo real
- 2: Estatísticas da amostra
- 3: Modelo estatístico
- 4: Amostra aleatória?
- 5: Avaliar a hipótese
- 6: Resumo



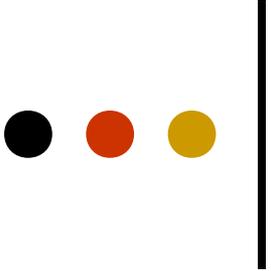
Modelo estatístico

- 1: Qual a população no mundo real
 - Americanos, 18-49 anos



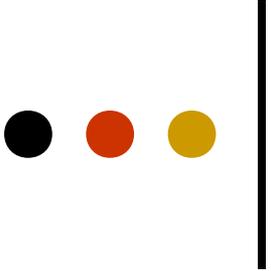
Modelo estatístico

- 1: Qual a população no mundo real
- 2: Estatísticas da amostra
 - mais que 1 parceiro nos últimos 12 meses:
 - Homens: 23%
 - Mulheres: 12%



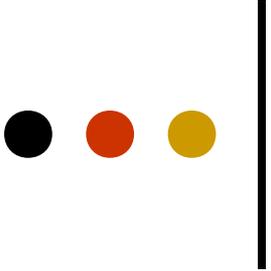
Modelo estatístico

- 1: Qual a população no mundo real
- 2: Estatísticas da amostra
- 3: Modelo estatístico
 - 2 Variáveis:
 - Sexo (M, F)
 - Mais que 1 parceiro (Sim, Não)



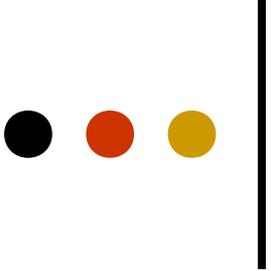
Modelo estatístico

- 1: Qual a população no mundo real
- 2: Estatísticas da amostra
- 3: Modelo estatístico
- 4: Amostra aleatória?
 - Sim
 - Participantes escolhidos aleatoriamente de forma a corresponder à distribuição de idade, educação, estado civil e etnias.



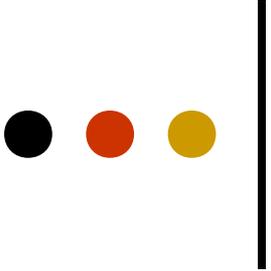
Modelo estatístico

- 1: Qual a população no mundo real
- 2: Estatísticas da amostra
- 3: Modelo estatístico
- 4: Amostra aleatória?
- 5: Avaliar a hipótese
 - Amostra 1500, erro de 2-3%
 - $23 - 12 = 11 > 4$ a 6% de margem
 - Diferença significativa



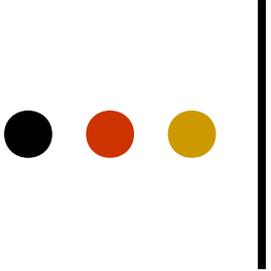
Modelo estatístico

- 6: Resumo
 - Esta amostra sugere que, na população considerada, os homens têm mais probabilidade de ter vários parceiros sexuais no período de seis meses.
 - Ou, pelo menos, de dizer que tiveram...



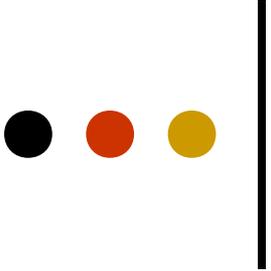
Modelos Causais

- Correlação e Causalidade
 - Correlação é simétrica:
 - Se há correlação entre A e B há correlação entre B e A.
 - Causalidade é assimétrica:
 - Se A causa B, B não causa A



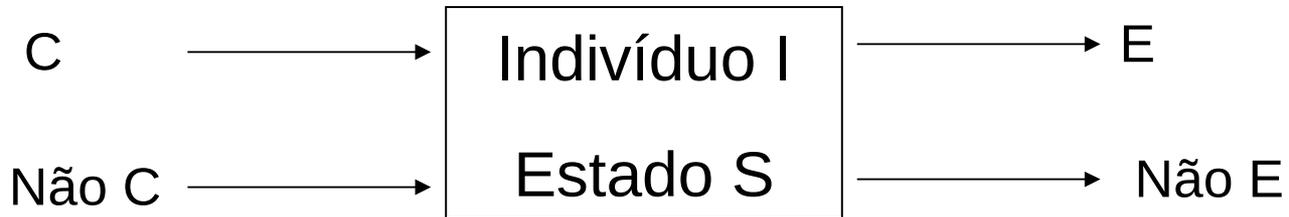
Modelos Causais

- Correlação e Causalidade
 - Causa:
 - A causa correlaciona-se com o efeito e há um mecanismo pelo qual a causa produz o efeito.
 - Contrafactuais
 - Um modelo causal não nos diz apenas o que acontece, mas o que tem de acontecer (o que aconteceria se).



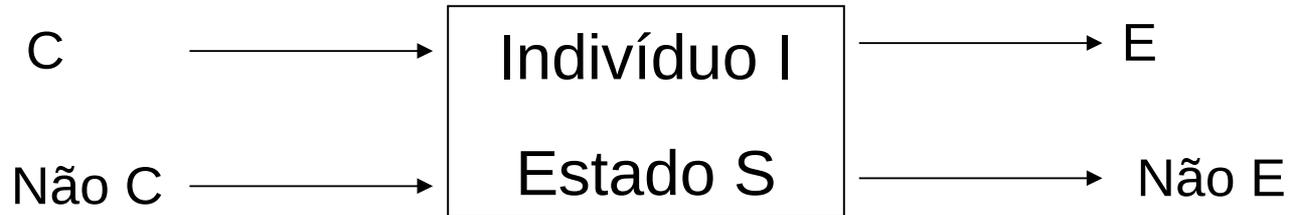
Modelos Causais

- Modelo Determinista
 - C é causa de E para I em S



Modelos Causais

- Modelo Determinista

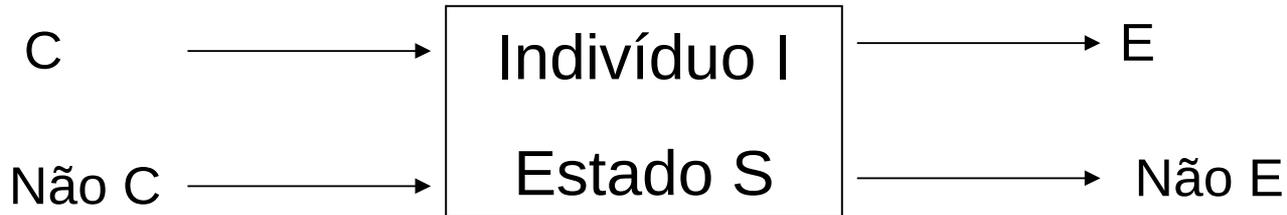


Para o indivíduo I no estado S, C é um factor causal:

- Positivo se C produz E e Não C produz Não E
- Negativo se Não C produz E e C produz Não E

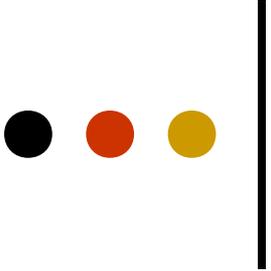
Modelos Causais

· Modelo Probabilístico



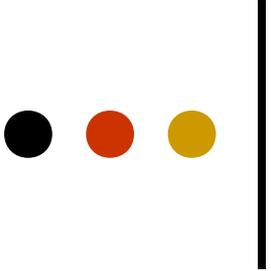
Para o I em S , C é um factor causal probabilístico:

- Positivo se $P(E|C) > P(E|\text{Não } C)$
- Negativo se $P(E|C) < P(E|\text{Não } C)$



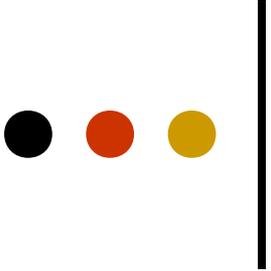
Modelos Causais

- Um ser humano:
 - Modelo determinista ou probabilístico?



Modelos Causais

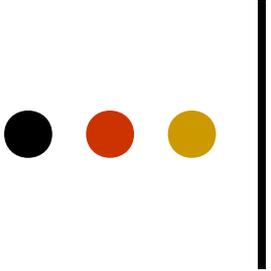
- Um ser humano:
 - Modelo determinista ou probabilístico?
 - Porque é que umas pessoas adoecem e outras não?
 - P: Porque calha, não há razão
 - D: Tem de haver alguma diferença
 - Felizmente, importa pouco na prática...



Modelos Causais

Pop.
Real (U)

$P_U(E)$



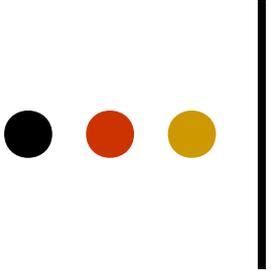
Modelos Causais

Pop. Hip.
Todos C (X)

$P_X(E)$

Pop.
Real (U)

$P_U(E)$



Modelos Causais

Pop. Hip.
Todos C (X)

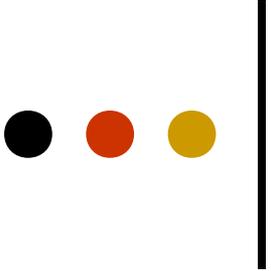
$P_X(E)$

Pop.
Real (U)

$P_U(E)$

Pop. Hip.
Não C (K)

$P_K(E)$



Modelos Causais

- Modelo População

- Para a população U, C é um factor causal:

- positivo se $P_x(E) > P_k(E)$
- negativo se $P_x(E) < P_k(E)$
- irrelevante se $P_x(E) = P_k(E)$

- Para a análise da população não importa se os modelos dos I são deterministas ou probabilísticos.

- O estado S é diferente conforme o individuo

$P_x(E)$

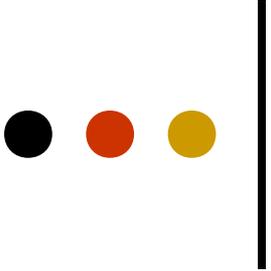
$P_u(E)$

$P_k(E)$

Pop. Hip.
Todos C (X)

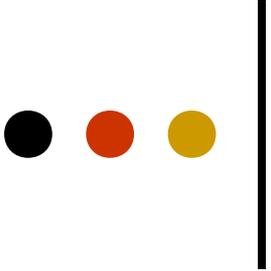
Pop.
Real (U)

Pop. Hip.
Não C (K)



Modelos Causais

- Ataques cardíacos são mais comuns entre viúvas. Por isso há quem sugira que enviudar causa ataques cardíacos.
 - Enviudar é um factor causal positivo?



Modelos Causais

U

Viúvas	Casadas

Correlação

Modelos Causais

U

Viúvas	Casadas

Correlação

Modelo Causal (Hipotético)

Para as mesmas mulheres:

X

Viúvas

O que aconteceria se todas enviuvassem

K

Casadas

O que aconteceria se nenhuma enviuvasse

Modelos Causais

U

Viúvas	Casadas

Correlação

Modelo Causal (Hipotético)

Se for irrelevante

X

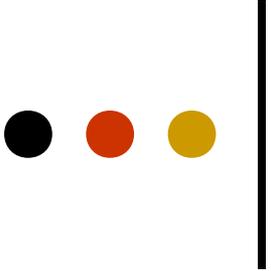
Viúvas

O que aconteceria se todas enviuvassem

K

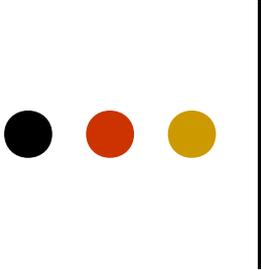
Casadas

O que aconteceria se nenhuma enviuvasse



Próximas

- Teórica 9
 - Análise de modelos causais, exemplos
- Práticas 7, 8, 9
 - Modelos teóricos, estatísticos, causais
 - Turnos P4 e P5: Aula 6 e 7 no dia 8-11
- Ficha 3 (28-11-2011)
 - Um destes
 - Identificar, analisar.



Dúvidas?

- Raciocínio científico
 - Conhecimento
 - crença verdadeira justificada
- Modelos teóricos
 - Realidade, modelo, dados, previsão
 - Consistência, alternativas
- Modelos estatísticos
 - Caso particular, inferir atributos da população pela amostra
- Causalidade
 - A causa geraria um efeito se presente