

MAE 5776

# ANÁLISE MULTIVARIADA

Júlia M Pavan Soler

[pavan@ime.usp.br](mailto:pavan@ime.usp.br)

IME - 1º Sem/2020

# Análise Multivariada

$$Y_{n \times p} = (Y_{ij}) \in \mathfrak{R}^{n \times p}$$

Já vimos  
😊

- Estatísticas Descritivas Multivariadas:
- Distribuição  $N_p$ , Distribuições Amostrais, Regiões de Confiança, MANOVA
- Análises Multivariadas Clássicas ( $n > p$ , *iid*): CP, AF, CoP, AC, AD, ACC, PLS
- Análises Multivariadas Esparsas ( $n \ll p$ , *iid*): CP, AD, ACC
- **“Componentes Principais” em Observações Dependentes (dados de famílias)**
- “Componentes Principais” em Dados Heterogêneos

Lista 4

⇒ Aprendizado de Estruturas

Modelos de Grafos Probabilísticos  
Modelos de Equações Estruturais  
Fatoração da Distribuição Conjunta

# Aprendizado de Estruturas – Inferência Causal

$$Y_{n \times p} = (Y_{ij}) \in \mathcal{R}^{n \times p}$$

Aprender (Estimar) a Estrutura de Dependência entre Variáveis  $\mathcal{R}^{p \times p}$

Dados multivariados com observações independentes ( $n > p$ ;  $p \uparrow$ )

$$Y_i \in \mathcal{R}^p \stackrel{iid}{\sim} (\mu; \Sigma)$$

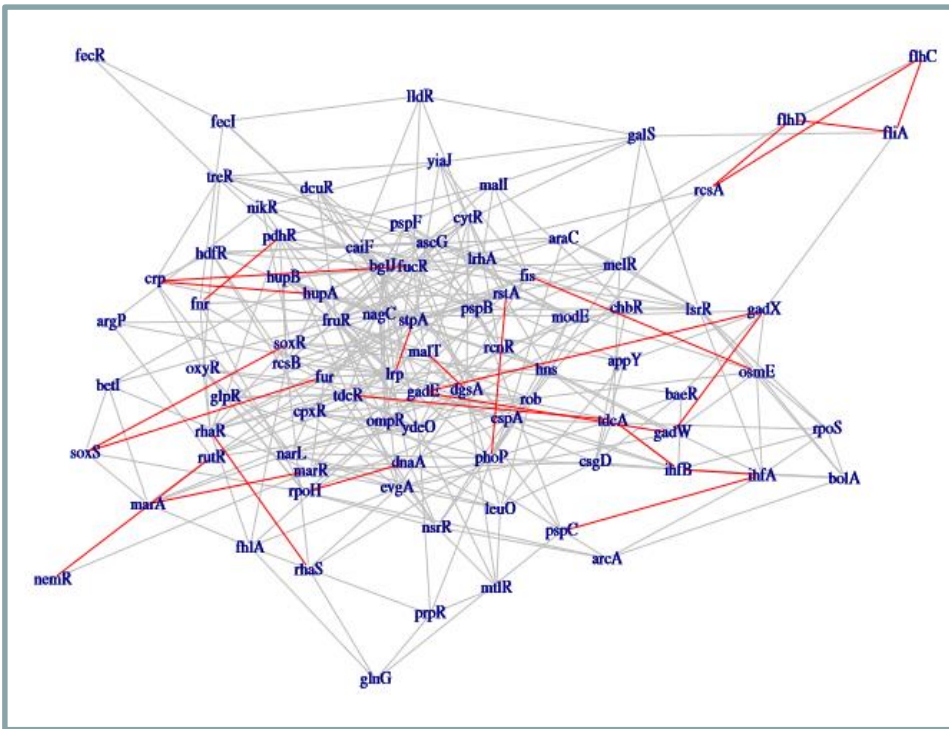
$\Sigma$  diagonal  
(variáveis independentes)



$\Sigma$   
Não Estruturada

Aprender (estimar) a estrutura de dependência entre as variáveis:

- Modelos de GRAFOS +
- Modelos de Equações Estruturais +
- Propriedades de Markov





Grafo Gaussiano de Independência Condicional ( $p=87$  variáveis em *E. coli.*; Drton and Maathuis, 2016)

# Aprendizado de Estruturas

## Correlação x Causa

Relação entre Variáveis: **Correlação** (é simétrica) *versus* **Causa** (é assimétrica)



- “**Correlação**” é uma relação não-direcionada entre variáveis  
“**Causa**” é uma relação direcionada (uma variável é causa ou efeito de outra)
- Inferências “Causais” são obtidas de **Ensaio Clínicos Controlados e Aleatorizados** que são padrão ouro em Planejamento de Experimentos.  
Desafio: extrair inferência causal a partir de **Estudos Observacionais**

No Aprendizado de Estruturas é necessário estabelecer suposições que possam capturar o padrão de dependências entre as variáveis.

Sistemas de **2 variáveis (X e Y)** não podem inferir estruturas causais.  
Ao incluir uma **terceira variável (X, Y e Z)** é possível inferir estruturas causais, sob certas suposições (Hausman, 1984; Papineau, 1985)

# Aprendizado de Estruturas – Inferência Causal

Como os sistemas respondem a intervenções ?

**Ensaio Controlado Aleatorizado**

(padrão ouro de inferência causal)

X

**Estudos observacionais**


(são mais fáceis de conduzir MAS podem conter muitos “ruídos, vícios”)

Avaliar padrões de dependência entre trios de variáveis:

*(X, Y) d-conectados dado Z:  
critério de orientação de  
arestas em um grafo*


**Caso 1**

Z é causa comum  
Z é confundidor




**Caso 2**

Z é efeito intermediário  
X tem efeito indireto sobre Y



**Caso 3**

Z é efeito comum  
**V-Estrutura**: colisão não conectada



$(X \perp Y)$  associados

**Modelos Probabilísticos  
Equivalentes Grafos Diferentes**

$(X \perp Y)$  independência

$(X \perp Y | Z)$  independência condicional


$(X \perp Y | Z)$  dependência condicional

# Aprendizado de Estruturas

Alguns resultados!


## Caso 1

Z é causa comum  
Z é confundidor



## Caso 2

Z é efeito intermediário  
X tem efeito indireto sobre Y



## Análise de Independência condicional

$$(X \perp Y | Z)$$

**Problemas:** mesma relação de independência (mesma distribuição conjunta) MAS sob diferentes Grafos.

$$P(X | Z) P(Y | Z) P(Z)$$

$$P(X) P(Z | X) P(Y | Z)$$

$$P(X, Y, Z)$$

$$P(X | Z) P(Y | Z) P(Z) = P(X, Z) P(Y | Z) = P(X) P(Z | X) P(Y | Z)$$

Como quebrar a equivalência de distribuições (geradas de “grafos” diferentes) ?

- Condições para que o modelo probabilístico determine unicamente o grafo:  
⇒ Teorema da Identificabilidade (ou da descoberta)


# Aprendizado de Estruturas

Alguns resultados!

## Correspondência entre Grafos e Modelos de Equações Estruturais (SEM)

### Caso 1


Z é causa comum  
Z é confundidor



$$P(X | Z) P(Y | Z) P(Z)$$

### Caso 2

Z é efeito intermediário  
X tem efeito indireto sobre Y



$$P(X) P(Z | X) P(Y | Z)$$

Correspondência entre  
“Grafos” e “SEM”

Cada efeito é uma função arbitrária (linear ou não) de sua causa direta e de um termo de erro. A função não é tão importante quanto a **independência dos termos de erro** (Spirtes, 1994)

Considere SEM lineares e com erros independentes:

$$Y = \beta_2 Z + e_{Y|Z}$$

$$X = \beta_1 Z + e_{X|Z}$$

$$(X \perp Y | Z) \Leftrightarrow e_{Y|Z} \perp e_{X|Z}$$

$$Y = \beta_2 Z + e_{Y|Z}$$

$$Z = \beta_1 X + e_{Z|X}$$

$$(X \perp Y | Z) \Leftrightarrow e_{Y|Z} \perp e_{Z|X}$$

Sob **termos de erros independentes**, tanto a representação SEM como a representação por Grafos permitem identificar a “independência condicional” entre as variáveis.

# Aprendizado de Estruturas


Alguns resultados!

Na correspondência entre Grafos e Modelos de Equações Estruturais é importante que o modelo probabilístico seja Fiel ao Grafo.

$$(X \perp Y | Z)$$

Caso 1

Z é causa comum (confundidor)



Efeito  $Z \rightarrow Y$  = Efeito direto + Efeito Indireto

$$Y = \beta_2 Z + \beta_3 X + e_{Y|Z,X}$$

$$X = \beta_1 Z + e_{X|Z}$$

$$Y = \beta_2 Z + \beta_3 (\beta_1 Z + e_{X|Z}) + e_{Y|Z,X}$$


$$= (\beta_2 + \beta_1 \beta_3) Z + \beta_3 e_{X|Z} + e_{Y|Z,X}$$

$\beta_2 = -\beta_1 \beta_3 \Rightarrow$  Efeito total nulo

O modelo probabilístico é infiel ao grafo

Caso 2

Z é efeito intermediário  
X tem efeito indireto sobre Y



Efeito  $X \rightarrow Y$  = Efeito direto + Efeito Indireto

$$Y = \beta_2 Z + \beta_3 X + e_{Y|Z,X}$$

$$Z = \beta_1 X + e_{Z|X}$$

$$Y = \beta_2 (\beta_1 X + e_{Z|X}) + \beta_3 X + e_{Y|Z,X}$$

$$= (\beta_3 + \beta_1 \beta_2) X + \beta_2 e_{Z|X} + e_{Y|Z,X}$$

$\beta_3 = -\beta_1 \beta_2 \Rightarrow$  Efeito total nulo

O modelo probabilístico é infiel ao grafo



# Aprendizado de Estruturas – Inferência Causal

Componentes da Inferência e do Aprendizado de Estruturas envolvendo “p” variáveis:

1. **Fatoração da Distribuição de probabilidades conjunta** (Lauritzen, 1990, 1996)  
Independência condicional e  
Propriedades de Markov (M-Pares de Variáveis, M-Local, M-Global)
2. **Modelos de Grafos Probabilísticos** (Pear, 1989; Verma e Pearl, 1990)  
d-separação (V-estrutura de colisão não-conectada:  $X \rightarrow Y \leftarrow Z$ )  
Fidelidade
3. **Modelos de Equações Estruturais (SEM)** (Boolen, 1989)  
Equações de Mensuração e Equações das variáveis latentes  
Linearidade  
Erros independentes

# Grafos: Diagramas de Representação “Causal”

Grafo é um conjunto de **vértices (V)** e **arestas (E)**:  $G=(V,E)$ ;  $E \subset V \times V$

**V**: variáveis (biométricas, sobrevivência, espectros de imagens, genótipos, etc)

**E**: arestas conectando V, representam “dependências” (não independência condicional) entre variáveis

- **Grafo Não Dirigido (UDG)**:  $X - Y - Z$

Definem Vizinhanças:  $nb_G(v) = \{w \in V; \{w,v\} \in E\}$


- **Grafo Dirigido (DAG, acíclico)**:  $X \rightarrow Y \rightarrow Z$

Definem estruturas de Pais e Descendentes:  $pa_G(v) = \{w \in V; \{w,v\} \in E\}$

$de_G(v) = \{w \in V; w=v \text{ ou } v \rightarrow \dots \rightarrow w \text{ em } G\}$


# Grafos: Diagramas de Representação “Causal”

- Grafos dirigidos:  $G=(V,E); E \subset V \times V$



- **DAGs: Grafos Acíclicos Dirigidos**

**SEM recursivos:** com termos de erros não correlacionados e sem relacionamentos cíclicos  
Matriz de Adjacência “B” é triangular inferior (arestas conectando variáveis/Coluna causando Linha)



- **DCGs: Grafos Cíclicos Dirigidos**

**SEM não recursivos:** matriz “B” geral mas sem elementos na diagonal (não ocorre self-loops)

Termos de “erro” e efeitos não são indicados no grafo (como acontece na representação de SEM).

# Aprendizado de Estruturas – Inferência Causal

## Modelos de Equações Estruturais (SEM) - Equações de Mensuração

Variáveis  
(vértices)

B: conecta  
os vértices

Covariáveis

Erro

Premissas  
clássicas

$$Y_{i \ p \times 1} = B_{p \times p} Y_{i \ p \times 1} + X_{i \ p \times q} \beta_{q \times 1} + e_{i \ p \times 1}; \quad e_i \stackrel{iid}{\sim} N_p \left( 0; \Sigma = I_p \sigma^2 \right)$$

$B_{p \times p}$ : **Matriz de Adjacência** (0 e 1's;  $B_{ii}=0$ )  
 $|I - B| = 1$  para DAGs

Modelo  
reduzido



$$Y_i = (I_p - B)^{-1} X_i \beta + (I_p - B)^{-1} e_i$$

Mistura de erros  
independentes

Matriz de covariância imposta pelo SEM:  $Cov(Y_i) = \Sigma_{YY} = (I - B)^{-1} \Sigma (I - B)^{-1'}$

**Objetivo da inferência: Estimar B e  $\beta$**

$$Y_i \stackrel{iid}{\sim} N_p \left( \left[ I_p - B_{p \times p} \right]^{-1} X_i \beta; \sigma^2 \left[ I_p - B_{p \times p} \right]^{-1} \left[ I_p - B_{p \times p} \right]^{-1'} \right)$$


Inferência: Algoritmo **SML**  
(Cai et al., 2013)

# Aprendizado de Estruturas – Inferência Causal

$p = 5$  variáveis “y”

B matriz de Adjacência: coluna causa linha

X matriz de covariáveis: cada variável “y” é afetada por um único Fator “q”

$$B = \begin{array}{c|ccccc} & y1 & y2 & y3 & y4 & y5 \\ \hline y1 & 0.0 & 0.8 & 0.0 & 0.0 & 0.8 \\ y2 & 0.0 & 0.0 & 0.0 & 0.0 & 0.8 \\ y3 & 0.0 & 0.0 & 0.0 & 0.8 & 0.0 \\ y4 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 \\ y5 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 \end{array}$$
$$X = \begin{array}{c|ccccc} & q1 & q2 & q3 & q4 & q5 \\ \hline y1 & 0.8 & 0.0 & 0.0 & 0.0 & 0.0 \\ y2 & 0.0 & 0.8 & 0.0 & 0.0 & 0.0 \\ y3 & 0.0 & 0.0 & 0.8 & 0.0 & 0.0 \\ y4 & 0.0 & 0.0 & 0.0 & 0.8 & 0.0 \\ y5 & 0.0 & 0.0 & 0.0 & 0.0 & 0.8 \end{array}$$


# Aprendizado de Estruturas – Inferência Causal

$p = 5$  variáveis

B matriz de Adjacência: coluna causa linha


X matriz de covariáveis: cada variável “y” é afetada por um único Fator “q”

B =

	y1	y2	y3	y4	y5
y1	0.0	0.8	0.0	0.0	0.0
y2	0.0	0.0	0.8	0.0	0.0
y3	0.0	0.0	0.0	0.0	0.8
y4	0.0	0.0	0.0	0.0	0.0
y5	0.8	0.0	0.0	0.0	0.0

X =

	q1	q2	q3	q4	q5
y1	0.8	0.0	0.0	0.0	0.0
y2	0.0	0.8	0.0	0.0	0.0
y3	0.0	0.0	0.8	0.0	0.0
y4	0.0	0.0	0.0	0.8	0.0
y5	0.0	0.0	0.0	0.0	0.8



# Aprendizado de Estruturas – Inferência Causal

Os **Algoritmos de Aprendizado de Estruturas** são principalmente baseados em Testes de Independência Condicional.

- **Passo 1.** Grafo Completo

- **Passo 2.** Aprendizado do Esqueleto (**UDG** - relações simétricas) *Eliminar arestas*

Independência condicional de **Pares de variáveis dado as restantes**

- **Passo 3.** Aprendizado do Grafo Direcionado (**DAG** – relações de causa/efeito)

Orientar as arestas: encontrar **V-estruturas**  $X \rightarrow Z \leftarrow Y$

Realizar testes de Independência Condicional de Pares de variáveis dado todo possível subconjunto condicionante.

3.1. X e Y não conectados:  $(X \perp Y)$

3.2. Pesquisar por Z, tal que  $(X \perp Y | Z)$

3.3. Se existir Z  $\Rightarrow$   $X \rightarrow Z \leftarrow Y$



Algoritmo IC  
Algoritmo PC

} Implementar um teste de independência condicional  
Oráculo da d-separação

# Independência Condicional – Coeficiente de Correlação Parcial

**Passo 2.** Aprendizado do Grafo não dirigido (**UDG**) é baseado em **Testes de**

## Correlação Parcial Nula

$$S = V \setminus \{X, Y\}, \quad X \perp Y | S \Leftrightarrow \rho(X, Y | S) = 0$$

Modelo Normal Multivariado:  $V_i \stackrel{iid}{\sim} N_p(\mu_{p \times 1}; \Sigma_{p \times p}) \Rightarrow \Sigma_{p \times p} = \begin{pmatrix} \sigma_{XX} & \sigma_{XY} & \Sigma_{XS} \\ \sigma_{YX} & \sigma_{YY} & \Sigma_{YS} \\ \Sigma_{SX} & \Sigma_{SY} & \Sigma_{SS} \end{pmatrix}$

Distribuição Condicional:

$$\begin{aligned} \Sigma_{XY.S} &= \begin{pmatrix} \sigma_{XX.S} & \sigma_{XY.S} \\ \sigma_{YX.S} & \sigma_{YY.S} \end{pmatrix} \\ &= \begin{pmatrix} \sigma_{XX} & \sigma_{XY} \\ \sigma_{YX} & \sigma_{YY} \end{pmatrix} - \begin{pmatrix} \Sigma_{XS} \\ \Sigma_{YS} \end{pmatrix} \Sigma_{SS}^{-1} \begin{pmatrix} \Sigma_{SX} & \Sigma_{SY} \end{pmatrix} \end{aligned}$$

$$\rho(X, Y | S) = \frac{\sigma_{XY.S}}{\sqrt{\sigma_{XX.S} \sigma_{YY.S}}} = \frac{-k_{XY}}{\sqrt{k_{XX} k_{YY}}}$$

Matriz de Precisão:

$$\Sigma^{-1} = (k_{XY})$$



# Testes de Independência Condicional

**Passo 2.** Aprendizado do Grafo não dirigido (**UDG**)

## Testes da Correlação Parcial Nula

**Alternativa 1:** Aprendizado de um UDG via **Matriz de Precisão**

$$V \stackrel{iid}{\sim} N_p(\mu_{p \times 1}; \Sigma_{p \times p}); \quad \Sigma^{-1} = (k_{XY}) \quad \rho(X, Y | S) = \frac{-k_{XY}}{\sqrt{k_{XX} k_{YY}}}$$

**Teste da Correlação Parcial Nula via a Estatística z de Fisher**

$$\begin{cases} H_0 : \rho_{XY.Z} = 0 \\ H_1 : \rho_{XY.Z} \neq 0 \end{cases} \quad z_{XY.S} = \frac{1}{2} \ln \left( \frac{1 + \hat{\rho}_{XY.S}}{1 - \hat{\rho}_{XY.S}} \right); \quad \sqrt{n - |S| - 3} |z_{XY.S}| \stackrel{H_0}{\sim} N(0;1)$$

# Testes de Independência Condicional

**Alternativa 2:** Aprendizado de um **UDG** via **Ajuste de Modelos Univariados**

Modelos Univariados:

- $Y_{n \times 1} = \mu_{Y|S} + \beta_S^Y 'S + e_{Y|S}; \quad e_{Y|S} \sim N(0; \sigma_{Y|S}^2)$
- $X_{n \times 1} = \mu_{X|S} + \beta_S^X 'S + e_{X|S}; \quad e_{X|S} \sim N(0; \sigma_{X|S}^2)$
- $Y_{n \times 1} = \mu_{Y|X,S} + \beta_{X|S}^Y 'X + \beta_{S|X}^Y 'S + e_{Y|X,S}; \quad e_{Y|X,S} \sim N(0; \sigma_{Y|X,S}^2)$

$$\rho(X, Y | S) = \frac{\sigma_{XY.S}}{\sqrt{\sigma_{XX.S} \sigma_{YY.S}}} = \frac{-k_{XY}}{\sqrt{k_{XX} k_{YY}}}$$

$$= \frac{\text{Cov}(e_{X|S}; e_{Y|S})}{\sigma_{X|S} \sigma_{Y|S}} = \beta_{X|S}^Y \frac{\sigma_{X|S}}{\sigma_{Y|S}}$$

$$\begin{cases} H_0 : \rho_{XY.Z} = 0 \Leftrightarrow \beta_{X|S}^Y = 0 \\ H_1 : \rho_{XY.Z} \neq 0 \end{cases}$$

**Método das Vizinhanças (Meinshausen and Buhlmann, 2006)**

Encontrar a vizinhança de cada vértice:  $nb(V_j) = \{V_i; \beta_{V_i|S}^{V_j} \neq 0, j \neq i (j, i = 1, \dots, p)\}$

Incluir arestas se:  $\hat{E} = \{(X, Y); X \in nb(Y) \text{ and } Y \in nb(X)\}$

Critério AND/OR

# Simulação de Grafos: “UDG”

Adèle Ribeiro, 2018,  
IME-USP

Entrada: Matriz de Correlação Parcial

```
> data.pCor
```

	[,1]	[,2]	[,3]
[1,]	1.0	0.6	-0.5
[2,]	0.6	1.0	<b>0.0</b>
[3,]	-0.5	0.0	1.0

Uso do R

```
#Gerar dados  $N_3$ 
```

```
#Aprender a estrutura
```

```
#Estimar as arestas via Método das Vizinhanças
```


```
#Teste z de Fisher
```

```
> nei_out$pCor$estimates
```

	V1	V2	V3
V1	NA	0.64450169	-0.48553853
V2	0.6445017	NA	0.04922369
V3	-0.4855385	0.04922369	NA

```
> nei_out$pCor$p.values
```

	V1	V2	V3
V1	NA	1.825967e-118	2.817058e-60
V2	1.825967e-118	NA	<b>1.198066e-01</b>
V3	2.817058e-60	1.198066e-01	NA



Não rejeitar a correlação  
parcial nula entre (V2,V3) | V1

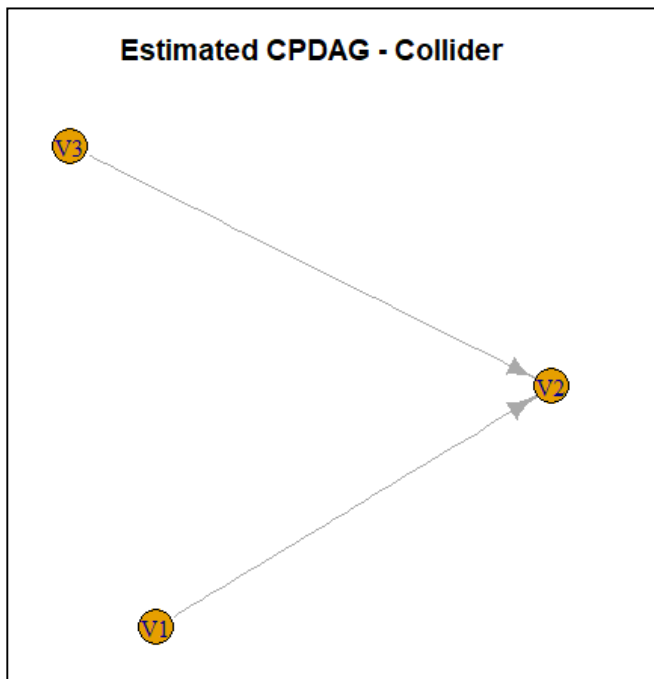
# Simulação de Grafos: “DAG”

## p=3 Variáveis

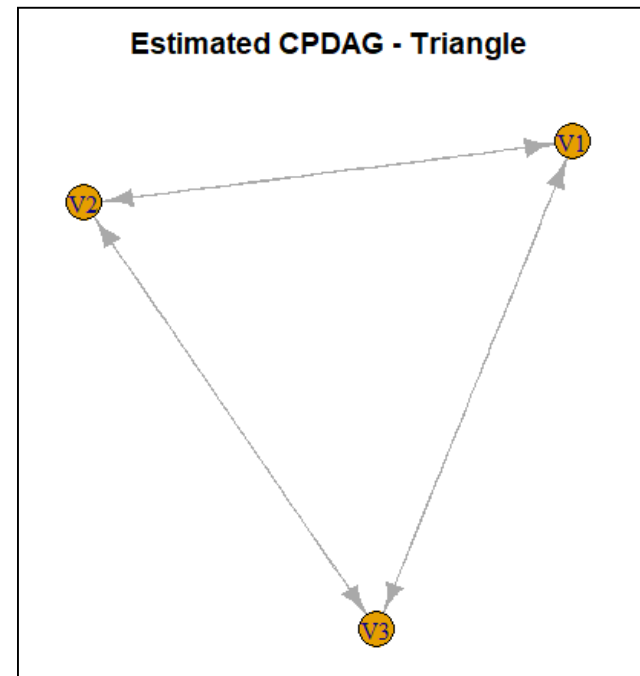
Adèle Ribeiro, 2018,  
IME/USP

```
# Possible types:  
# - chain: V1 -> V2 -> V3  
# - collider: V1 -> V2 <- V3  
# - fork: V1 <- V2 -> V3  
# - triangle: V1 -> V2 <- V3 <- V1  
# - independent: V1 V2 V3
```

#Gerar dados via Modelos de Mensuração (SEM)  
#Entrar com os Betas: no exemplo, Beta=0 e 0.8  
#Testes de Independência Condicional com  
# p-valor=0.01 e Correção de Bonferroni



A V-estrutura (colisor) pode ser aprendida, as demais nem sempre!.



# Simulação de Grafos: DAG


## p=3 Variáveis

Adèle Ribeiro, 2018


```
# Possible types:  
# - chain: V1 -> V2 -> V3  
# - collider: V1 -> V2 <- V3  
# - fork: V1 <- V2 -> V3  
# - triangle: V1 -> V2 <- V3 <- V1  
# - independent: V1 V2 V3
```

# Estruturas *Chain* e *fork* têm a mesma distribuição conjunta e não podem ser estatisticamente distinguíveis.

Estimated CPDAG - Fork



Estimated CPDAG - Chain




# Simulação de Grafos: “DAG”

## p=5 Variáveis


Adèle Ribeiro, 2018

```
# Possible types:  
# - multichain  
# - multicollider: V2, V3, and V4 are colliders and sink/terminal vertices;  
#                   V1 and V5 are source nodes;  
# - multifork: V2, V3, and V4 are source nodes;  
#             V1 and V5 are colliders and sink/terminal vertices.
```

Estimated CPDAG - Multicollider



Estimated CPDAG - Multifork



Estimated CPDAG - Multichain

