

‘Como testar um modelo?’

Modelo Geral de Equações Estruturais (MARÔCO, 2013)

Docente: Daniela Craveiro
dcraveiro@iseg.ulisboa.pt

**No final desta aula,
@s alun@s deverão:**


- **Compreender noções básicas dos modelos de equações estruturais**
- **Compreender a diferença entre variáveis latentes e manifestas**
- **Compreender o processo de definição e análise de MEQ**
- **Gerar modelos de equações estruturais com recurso do programa AMOS**
- **Interpretar resultados dos modelos de equações estruturais com recurso do programa AMOS**

MODELOS DE EQUAÇÕES ESTRUTURAIS (Structural Equation Modelling):

extensão dos modelos GLM; técnica de modelação generalizada,
para testar a validade de modelos teóricos.

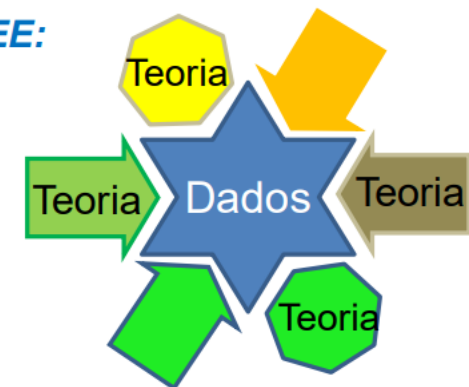
Segue uma abordagem diferente:

Estatística Clássica:



1. Qual o modelo que descreve os dados observados? *Método Exploratório*
2. Dados levam à dedução de Teorias
3. Novos dados, novas teorias

AMEE:

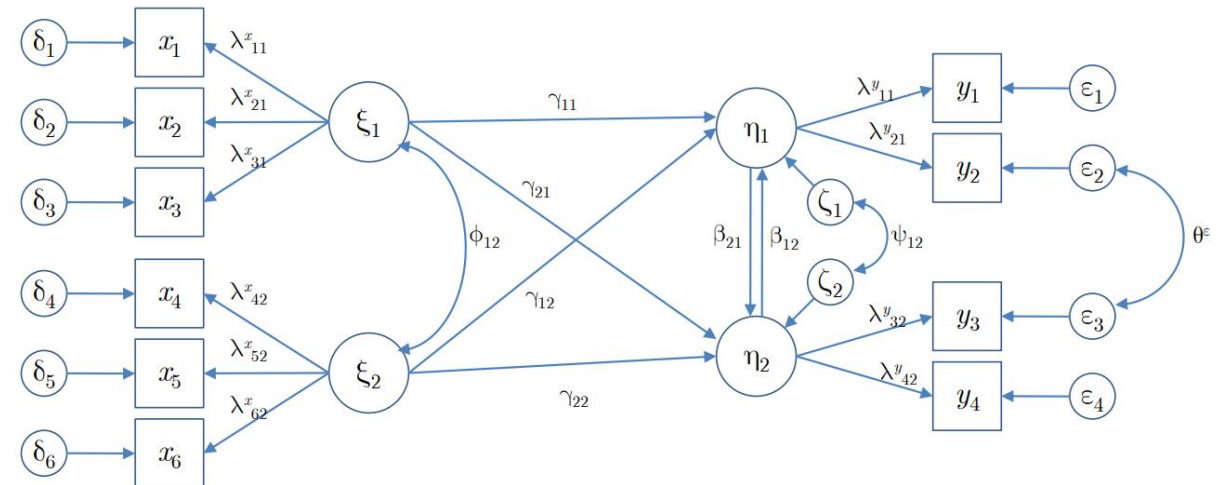


1. Poderá este modelo explicar/gerar os dados observados? *Método Confirmatório*
2. A teoria é o “motor” do processo
3. Teorias diferentes podem ser testadas por formalização e avaliação de modelos distintos

MODELOS DE EQUAÇÕES ESTRUTURAIS

Vantagens face às abordagens clássicas

1. Inclui no modelo variáveis latentes e manifestas (e o erro previsto)
2. Permite testar modelos complexos com vários tipo de variável e de relações (Permite testar ajustamento global de modelos e significância individual de parâmetros num enquadramento teórico que engloba vários tipos de modelos lineares)
3. Softwares intuitivos AMOS e SMART PLI



AS VARIÁVEIS

- **Variáveis manifestas ou variáveis observadas:** São variáveis medidas, manipuladas ou observadas diretamente.
- **Variáveis latentes, fatores ou constructos:** São variáveis não diretamente observáveis ou mensuráveis, sendo a sua existência indicada pela sua manifestação em variáveis indicadoras ou manifestas.
- **Variáveis independentes ou exógenas:** as causas destas variáveis residem fora do modelo, i.e. não são influenciadas por nenhuma outra variável no modelo.
- **Variáveis dependentes ou endógenas:** as causas da variação destas variáveis residem no modelo, i.e. a variação destas variáveis é explicada por variáveis presentes no modelo

AS COMPONENTES

- **Modelo de Medida** : define a forma como os constructos hipotéticos ou variáveis latentes são operacionalizados pelas variáveis observadas ou manifestas
- **Modelo Estrutural** : define as relações causais ou de associação entre as variáveis latentes

- **Formalmente:**

Modelo de Medida:

$$\text{v.d.: } \mathbf{y} = \mathbf{\Lambda}_y \boldsymbol{\eta} + \boldsymbol{\varepsilon}$$

$$\text{v.i.: } \mathbf{x} = \mathbf{\Lambda}_x \boldsymbol{\xi} + \boldsymbol{\delta}$$

Modelo Estrutural:

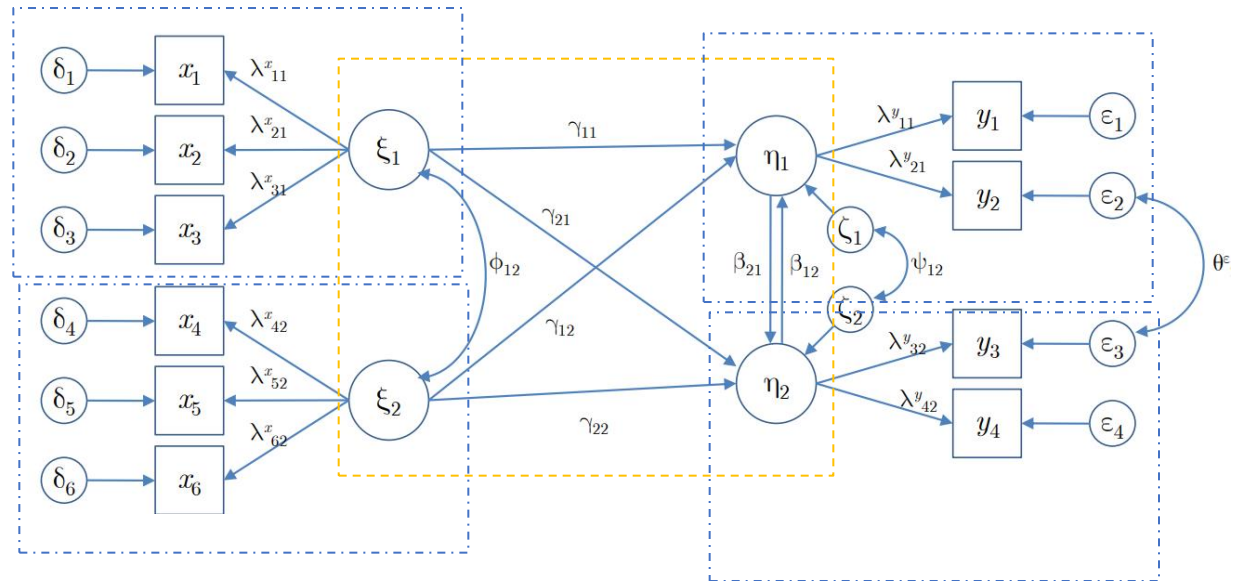
$$\boldsymbol{\eta} = \mathbf{B}\boldsymbol{\eta} + \mathbf{\Gamma}\boldsymbol{\xi} + \boldsymbol{\zeta}$$

assumindo que (pressupostos):

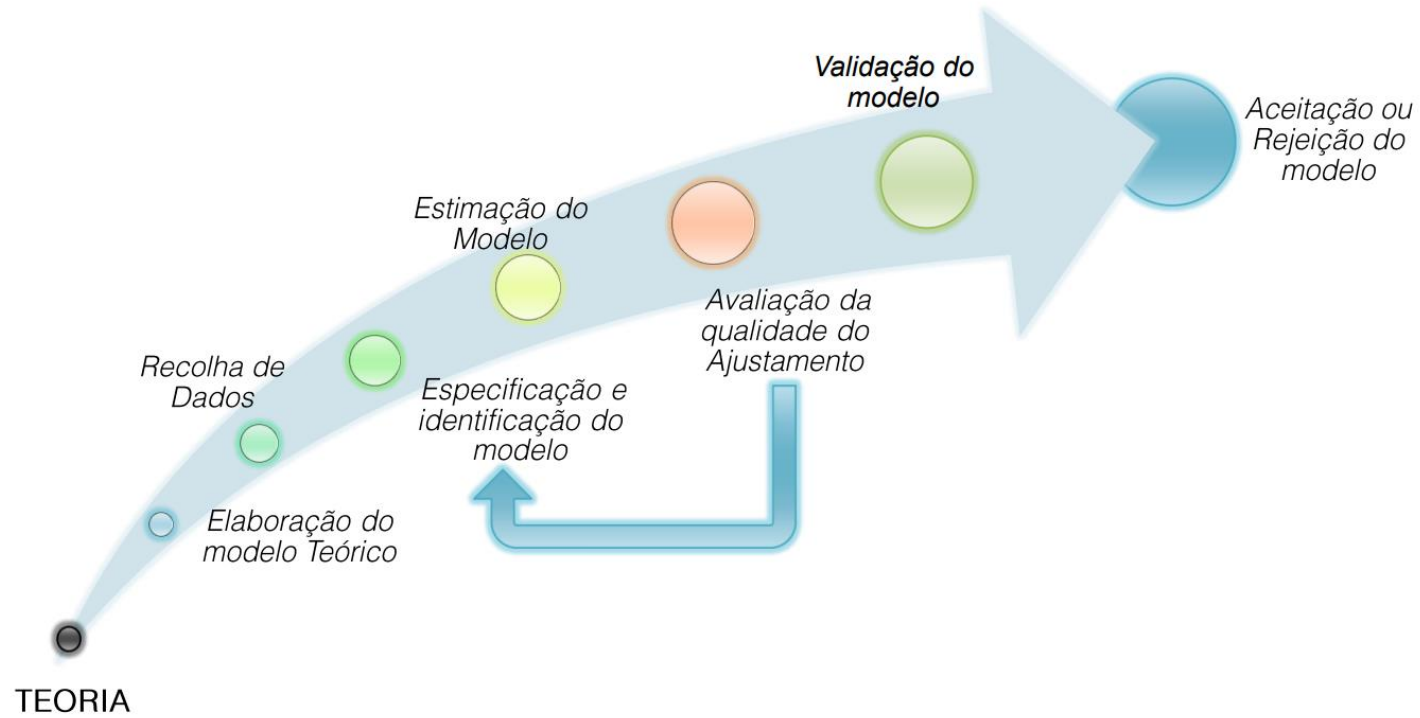
- a. $\boldsymbol{\varepsilon}$ e $\boldsymbol{\eta}$ são independentes
- b. $\boldsymbol{\delta}$ e $\boldsymbol{\xi}$ são independentes
- c. $\boldsymbol{\zeta}$ e $\boldsymbol{\xi}$ são independentes
- d. $\boldsymbol{\zeta}$, $\boldsymbol{\varepsilon}$ e $\boldsymbol{\delta}$ são mutuamente independentes
- e. Os valores esperados dos erros é 0.
- f. $\mathbf{B}_{ii}=0$ (uma v.d. não é causa e efeito dela mesmo) e $(\mathbf{I}-\mathbf{B})$ é não singular (i.e. tem inversa)

AS COMPONENTES

- **Modelo de Medida:** define a forma como os constructos hipotéticos ou variáveis latentes são operacionalizados pelas variáveis observadas ou manifestas - . -
- **Modelo Estrutural:** define as relações causais ou de associação entre as variáveis latentes - -
- **Graficamente:**




A ESTRATÉGIA



1. DEFINIR O MODELO TEÓRICO

- “Desenho” formal do modelo, que ilustra as hipóteses sobre o modelo de medida e sobre o modelo estrutural:
- **Decidir:**
 1. Que variáveis manifestas operacionalizam que variáveis latentes; erros correlacionados?
 2. Que relações causais entre v. latentes e/ou v. manifestas devem ser incluídas / excluídas?
 3. Que associações (não-causais) devem ser incluídas/omitidas do modelo?

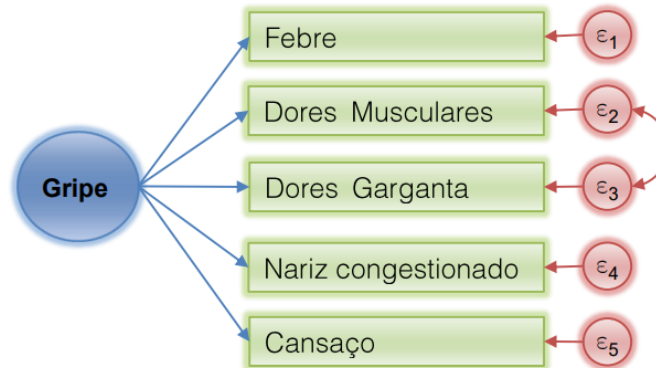


2. ESPECIFICAÇÃO

- Uma das etapas mais complexas...
- Implica tomar decisões e assumir alguns pressupostos
- Em primeiro lugar temos de definir que tipo de modelo de medida: Modelo reflectivo ou formativo?

Modelos reflectivos:

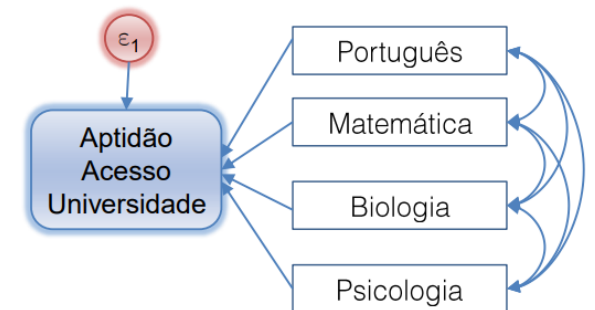
As v. latentes 'reflectem-se' nos itens;
As v. latentes manifestam-se através das v. manifestas
Os itens devem estar correlacionados positivamente



(estimáveis pelos modelos de Eq. Estruturais)

Modelos formativos:

As 'v. latentes' são 'formadas' pelas manifestas;
Os itens podem estar ou não correlacionados, positivamente ou negativamente



(Esta Aptidão de Acesso Univ. não é verdadeiramente latente, já que é uma combinação de v. manifestas (média ponderada). Não é estimável com AEE, mas sim com PLS)


2. ESPECIFICAÇÃO

- **Uma das etapas mais complexas...**
- **Implica tomar decisões e assumir alguns pressupostos**
- **Depois identificar as ligações, erros e possíveis associações com base nas decisões (os softwares ajudam nesta definição de parâmetros)**

Algumas 'regras' de especificação:


Modelo de Medida (AFC)

1. Factores comuns latentes (ξ) causam as v. manifestas (x_1, \dots, x_i). O comportamento das v. manifestas resulta da manifestação dos factores latentes;
2. A variância das v. manifestas (e.g. erros de medida) que não é explicada pelos factores comuns latentes é explicado por **factores específicos latentes** ($\epsilon_1, \dots, \epsilon_i$);
3. Os **erros de medida são geralmente independentes (mas podem estar correlacionados)** indicando uma fonte de variação comum dos itens não explicada pelos factores comuns presentes no modelo).



Modelo Estrutural (RL)

1. As relações são 'desenhadas' de causa-para-efeito
2. A variância da v. exógenas não explicada pela combinação das v. endógenas é explicada por 'erros' (**Disturbances** ou Perturbações)



3. ESTIMAÇÃO

- **Contrariamente ao paradigma clássico, nesta abordagem modelamos as matrizes de variâncias-covariâncias (ou de correlações) das variáveis manifestas (não os dados individuais!)**
- O objectivo da AEE é então encontrar um vector de estimativas dos parâmetros do modelo (q) que reproduza o melhor possível a matriz S das v. manifestas na população
- **Os softwares de AEE utilizam um algoritmo iterativo que minimiza uma função da diferença**

Métodos de ajustamento mais usados:

- **Máxima verosimilhança (ML)**
- Mínimos quadrados não-ponderados (ULS)
- Mínimos quadrados generalizados (GLS)
- Mínimos quadrados ponderados generalizados (WLS)
- **Mínimos Quadrados Parciais (PLS)**



3. ESTIMAÇÃO

AMOS vs PLS (by ChatGPT)

Argumentos explicados em:

Dash, G., & Paul, J. (2021). CB-SEM vs PLS-SEM methods for research in social sciences and technology forecasting. *Technological Forecasting and Social Change*, 173, 121092.


<https://doi.org/10.1016/j.techfore.2021.121092>

Critério	AMOS (CB-SEM)	PLS (PLS-SEM)
Objetivo	Testar e confirmar teorias	Explorar relações e prever variáveis
Base	Covariância	Variância
Tamanho da amostra	Grande ($n \geq 200$)	Pequena a moderada ($n < 200$)
Normalidade dos dados	Requer normalidade multivariada	Não requer normalidade
Foco analítico	Ajustamento global (fit global)	Poder explicativo e preditivo (R^2 , Q^2)
Teoria	Base sólida e prévia	Áreas com teorias emergentes ou em desenvolvimento
Complexidade do modelo	Adequado para modelos complexos	Adequado, mas limitado a modelos exploratórios
Exemplo de aplicação	Validação de teorias psicológicas	Modelos de satisfação do cliente

3. AVALIAÇÃO DA QUALIDADE


- (1) Teste do Qui-quadrado
- (2) Índices de qualidade de ajustamento
- (3) Análise de resíduos, estimativa de parâmetros e fiabilidade individual de indicadores

Estatística Clássica:



1. Qual o modelo que descreve os dados observados? *Método Exploratório*
2. Dados levam à dedução de Teorias
3. Novos dados, novas teorias

AMEE:



1. Poderá este modelo explicar/gerar os dados observados? *Método Confirmatório*
2. A teoria é o “motor” do processo
3. Teorias diferentes podem ser testadas por formalização e avaliação de modelos distintos

3. AVALIAÇÃO DA QUALIDADE

(1) Teste do Qui-quadrado

Hipótese nula: a matriz de covariância populacional é igual à matriz de covariância estimada pelo modelo

Queremos aceitar a hipótese nula, neste caso

Devemos reportar mas não é bom indicador :

Muito sensível à dimensão da amostra
(amostras pequenas: raramente rejeita H_0 ,
Amostras grandes: Rejeita quase sempre H_0)
Muito sensível à violação da normalidade multivariada (com risco de rejeição de bons modelos e aceitação de modelos maus!)

3. AVALIAÇÃO DA QUALIDADE

(2) Índices de qualidade de ajustamento

Avaliam a distância relativa entre a matriz dos dados e a matriz da população.

**Existem centenas!
Tipos de indicadores**



- A. Índices Absolutos:** Avaliam a qualidade do modelo per se, sem comparação com outros modelos: RMR, GFI
- B. Índices Relativos:** Avaliam a qualidade do modelo sob teste relativamente ao modelo com pior ajustamento (mod independência) ou melhor possível (mod saturado): NFI, CFI C
- C. Índices de Parcimónia:** Índices relativos que incluem uma penalização devida à complexidade do modelo: AGFI, PGFI, PCFI
- D. Índices baseados na teoria da informação:** Apropriados para comparar vários modelos alternativos que ajustem aos dados (AIC, BIC, ECVI)

3. AVALIAÇÃO DA QUALIDADE (2)

(2) Índices de qualidade de ajustamento

Avaliam a distância relativa entre a matriz dos dados e a matriz da população.

Índices recomendados de acordo com Marôco, 2013

Estatística	Valores de Referência
X² e p-value (H ₀ : O Ajustamento é perfeito) (Macro do AMOS: \cmin; \p)	Quanto menor melhor p>0.05
X²/df (Macro do AMOS: \cmindf)	< 5 – ajustamento sofrível ≤ 2 - ajustamento aceitável ~ 1 – ajustamento bom
CFI (Macro do AMOS: \cfi) GFI (Macro do AMOS: \gfi)	<0.8 – ajustamento mau [0.8;0.9[– ajustamento sofrível ≥ 0.9 – ajustamento muito bom
PGFI (Macro do AMOS: \pcfi) PCFI (Macro do AMOS: \gfi)	< 0.6 – Ajustamento mau [0.6; 0.8[- Ajustamento bom ≥0.8 – Ajustamento muito bom
RMSEA (com I.C. 90%) e p-value (H ₀ : rmsea≤0.05) (Macro do AMOS: \rmsea; \pclose)	> 0.10 - Inaceitável]0.05;0.10] – ajustamento sofrível ≤0.05 – ajustamento bom p-value ≥0.05 (≥0.5 segundo Jöreskog)
AIC (Macro do AMOS: \aic) ECVI (Macro do AMOS: \ecvi)	Só para comparar modelos Quanto menor, melhor...

3. AVALIAÇÃO DA QUALIDADE (3)

(2)) Análise de resíduos, estimativa de parâmetros e fiabilidade individual de indicadores

Ou seja: O modelo pode ter um bom ajustamento global, mas ainda assim apresentar um mau ajustamento local. Para fazer o diagnóstico de possíveis problemas locais:

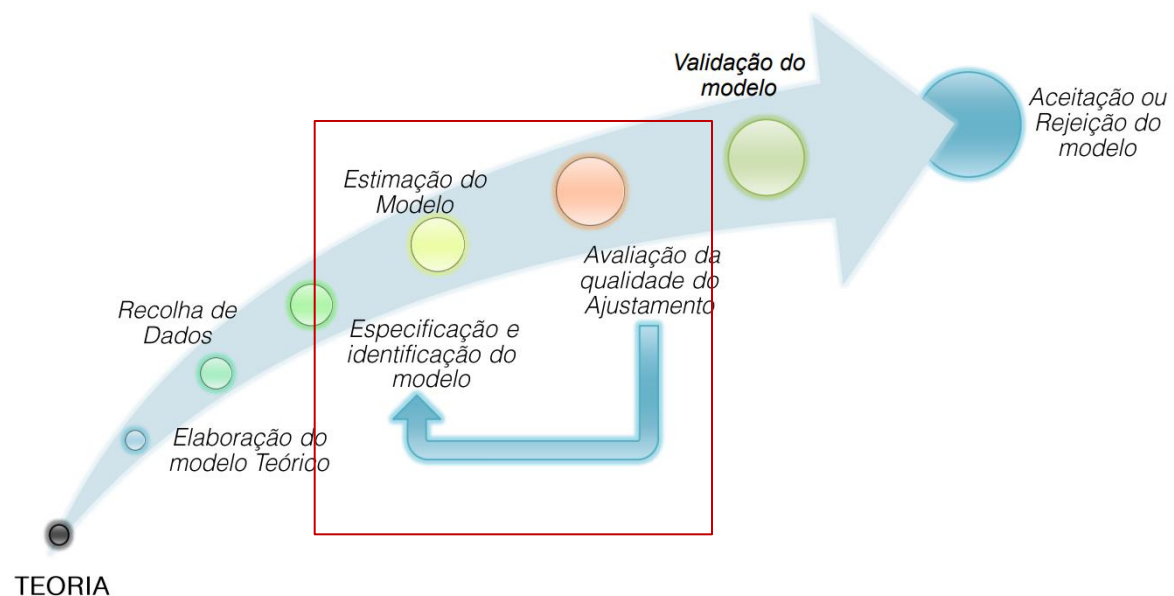
- A. Avaliar os resíduos estandardizados (problemas: resíduos > 2 , outliers)
- B. Avaliar os erros-padrão assintóticos dos parâmetros do modelo e sua significância (problemas: erros-padrão superiores (2x) à estimativa do parâmetro; parâmetros não significativos)
- C. Fiabilidade individual dos indicadores/manifestas (problemas: Valores de $R^2 < ,025$)

3. AVALIAÇÃO DA QUALIDADE (4)

(2) E se a qualidade não for boa??

É prática corrente, modificar o modelo eliminando vias não significativas, libertando parâmetros anteriormente fixos, fixando parâmetros anteriormente livres, correlacionar erros, ...

Os softwares também dão outras pistas: Índices de modificação!



- Marôco recomenda apenas alterar o modelo se houver fundamentos teóricos para + $MI > 11$
- *A atualização do modelos deve ser feita sequencialmente, começando por libertar o parâmetro com maior MI

3. AVALIAÇÃO DA QUALIDADE (4)

(2) E se a qualidade não for boa??

É prática corrente, modificar o modelo eliminando vias não significativas, libertando parâmetros anteriormente fixos, fixando parâmetros anteriormente livres, correlacionar erros, ...

Os softwares também dão outras pistas: Índices de modificação!

Maroco recomenda apenas alterar o modelo se houver fundamentos teóricos para o fazer e/ou de $MI > 11$

A atualização do modelos deve ser feita sequencialmente, começando por libertar o parâmetro com maior MI até chegar ao parâmetro de menor MI.

5. VALIDAÇÃO

Pressupostos

1. Normalidade multivariada
2. Linearidade: aplicado à matriz de correlações (entre manifestas)
3. Covariâncias amostrais não-nulas
4. Múltiplos indicadores para cada latente
5. Ausência de Multicolinearidade
6. Amostras de “grande” dimensão
7. Modelos sobre-identificados
8. Medida “forte”
9. Sem outliers

Pode ser avaliada com:

1. Assimetria (skewness - "sk") e Curtose (kurtosis - "ku") | Kline (1998): Valores de $|Sk| < 3$ $|Ku| < 8$
2. Gráficos de dispersão
3. Matriz de correlações ($p < 0,05$)
4. Múltiplos indicadores | Modelo
5. Ausência de Multicolinearidade | VIF
6. $N > 200 - 400$; 15 sujeitos por variável manifesta; 5 sujeitos por parâmetro a estimar
7. Medidas de ajustamento local
8. Escala (ordinal) deve ter pelo menos 5 pontos
9. AMOS testa a distância de Mahalanobis *Convém que p_1 seja pequeno (0.05-0.10), e p_2 seja grande ($> 0.05-0.10$), caso contrário a observação deve ser um outlier multivariad

4. REPORTE

Recomendações:

- Reporte baseado nas estimativas estandardizadas
- Inclui informação sobre a variância explicada pelo modelo de medida (em geral e para cada item);
- Inclui informação sobre a variância explicada pelo modelo estrutural (em geral e para cada VD);
- Inclui representação visual do modelo

Análise Estatística

O modelo de moderação do Conhecimento prévio a matemática sobre a Motivação matemática e a influência destas variáveis na performance a matemática foi avaliado por intermédio de um modelo de equações estruturais com efeito de moderação. O factor latente de moderação foi definido pelo produto, em pares, dos itens reflexos dos factores ‘Conhecimento Prévio’ e ‘Motivação Matemática’. O ajustamento do modelo de moderação foi efectuado em duas etapas: a primeira de validação do modelo de medida, e a 2ª de ajustamento do modelo de moderação. O ajustamento do modelo foi feito por recurso ao software AMOS (v. 17, SPSS Inc, Chicago, IL). Na avaliação da qualidade do ajustamento utilizaram-se os índices *CFI*, *GFI* e *PCFI*, *PGFI* tendo-se considerado que estes indicavam um bom ajustamento para valores superiores a 0.9 e 0.6, respectivamente. Utilizou-se também o *RMSEA* com I.C. a 90% e a probabilidade do $rmsea \leq 0.05$. Considerou-se que um I.C. para o *RMSEA* a 90% com limite superior inferior a 0.10 é indicador de um ajustamento razoável, e que o ajustamento é muito bom quando o limite superior do I.C. é inferior a 0.05 (Maroco, 2008). A significância do efeito de moderação foi avaliada com um teste à significância do coeficiente de trajectória associada ao efeito de moderação.

Resultados

A figura 1 ilustra as estimativas dos parâmetros quer do modelo de medida (pesos factoriais) quer do modelo estrutural de moderação. Observou-se um efeito de moderação do Conhecimento prévio sobre a Motivação matemática na performance a matemática ($\beta_{PM,CM*MM}=0.220$; $p<0.001$). Sendo o efeito de moderação positivo podemos afirmar que quanto maior for o conhecimento prévio maior será o efeito da motivação matemática sobre a performance a matemática. Observaram-se ainda efeitos directos do Conhecimento ($\beta_{PM,CM}=0.429$; $p<0.001$) e Motivação ($\beta_{PM,MM}=0.409$; $p<0.001$) estatisticamente significativos.

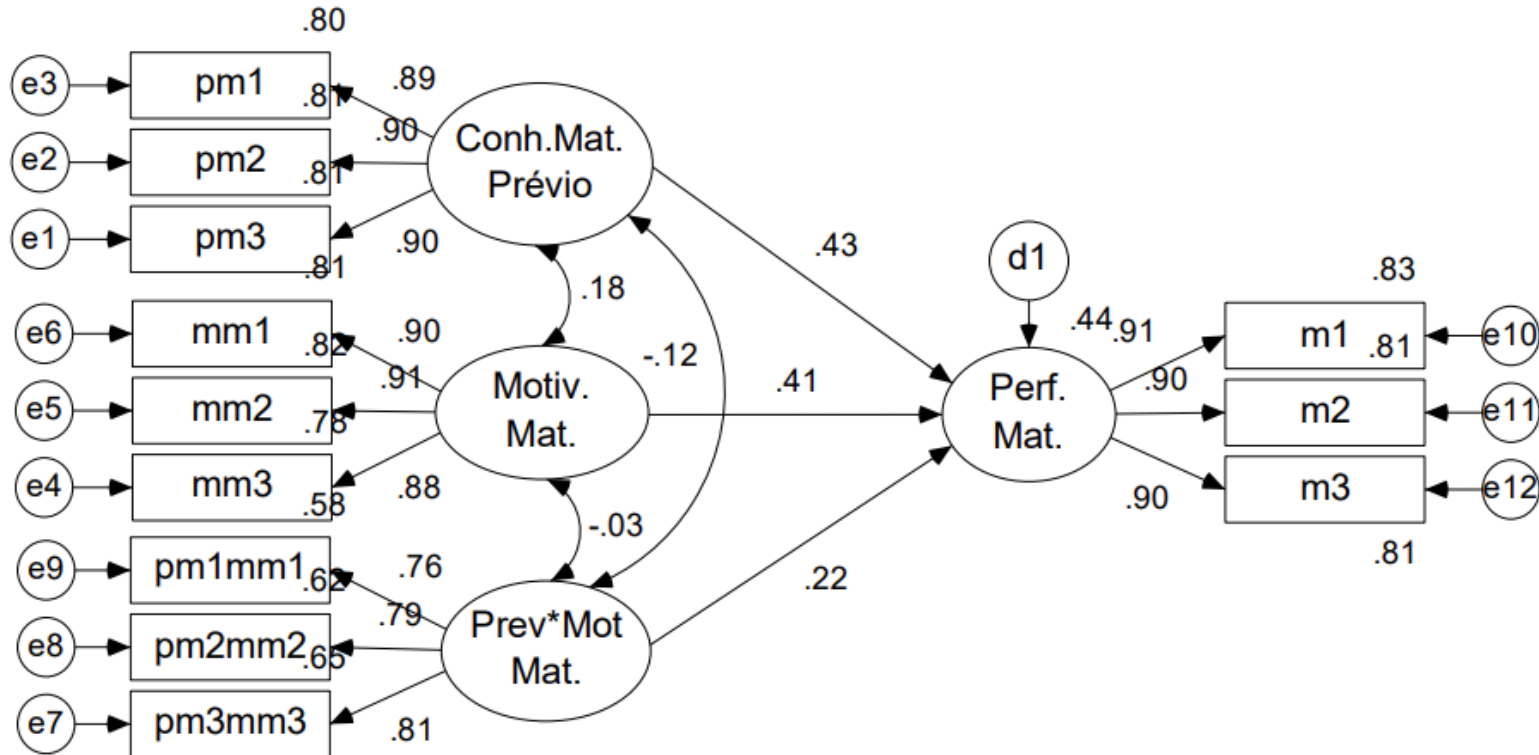


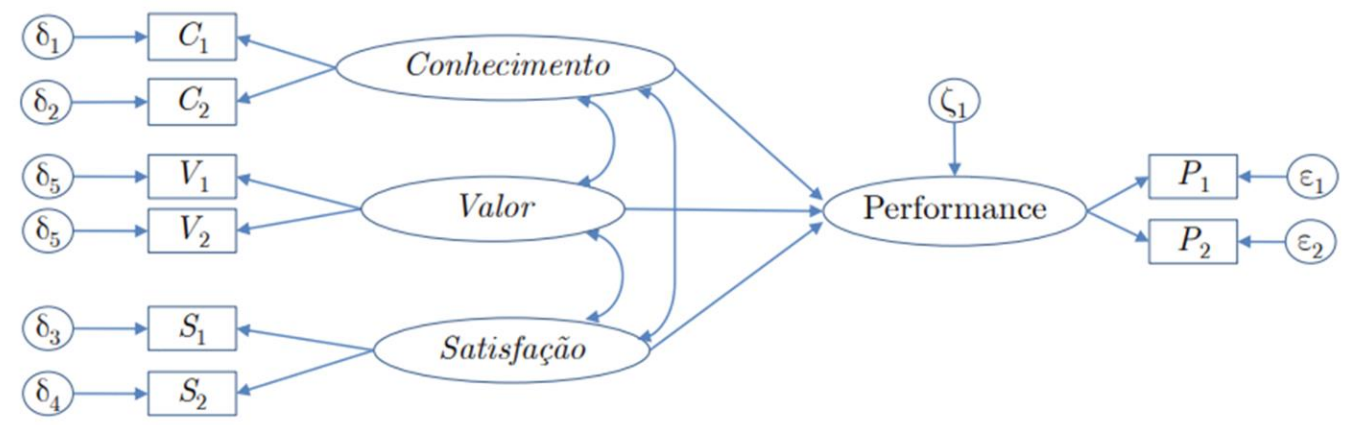
Figura 1. Modelo de moderação do conhecimento prévio sobre a motivação Matemática na performance a Matemática
 ($X^2/df = 1.8$; $CFI = 0.991$; $GFI = 0.973$; $PCFI = 0.721$; $PGFI = 0.599$ e $RMSEA = 0.04$; $p = 0.891$; I.C. 90%]0.026; 0.053[)

Modelos de equações estruturais

Objetivo: Gerar um modelo com variáveis manifestas e latentes com o programa AMOS

ANÁLISE DE DADOS EM GRH

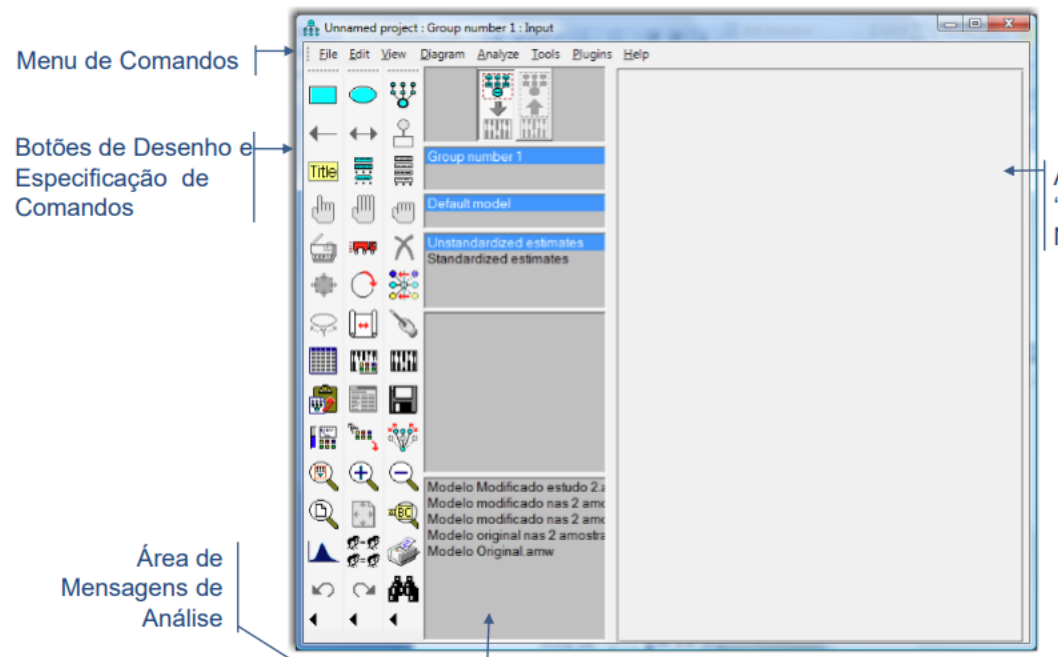
Segundo Warren, White & Fuller, (1974) a performance de um conjunto de administradores de uma cooperativa agrícola é função de um conjunto de variáveis latentes que incluem o Conhecimento técnico, o Valor e a Satisfação dos gestores. Cada uma destas variáveis foi avaliada com um teste constituído por duas metades equivalentes. O modelo GEE proposto é ilustrado na figura seguinte:



Ajuste o sub-modelo de medida, e o modelo geral. Avalie a qualidade do ajustamento em cada uma das etapas.

1. Desenhar o modelo

Organização:






Botão	Função
	Desenhar variável manifesta
	Desenhar variável latente
	Desenhar modelo de medida
	Desenhar trajetória causal (Causa para efeito)
	Desenhar relação correlacional
	Adicionar 'erros' às variáveis
	Seleccionar um objecto
	Seleccionar todos os objectos
	De-seleccionar todos os objectos
	Copiar objecto
	Mover objecto
	Apagar objecto
	Especificar propriedades dos objectos



Desenhar o modelo


Botão	Função
	Visualizar variáveis na base de dados
	Visualizar variáveis no modelo
	Seleção do ficheiro de dados e grupos para análise multi-grupos
	Especificação das propriedades da análise (método de estimação; outputs, ...)
	Calcular estimativas dos parâmetros e medidas de ajustamento do modelo
	Visualizar o Output com resultados da análise
	Modo de 'Desenho' do modelo
	Modo de 'Visualização' das estimativas dos Parâmetros e estatísticas de ajustamento
	Estimação Bayesiana
	Análise Multi-grupos
	Pesquisa de Especificação (Specification search)


Estimar o modelo

1. Desenhar o modelo

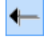
- ▶ Selecciona a ferramenta de desenho do modelo de medida  .
(O cursor, na área de desenho, passará de  para )
- ▶ Clique, com o botão esquerdo na área de desenho, e arraste o cursor para desenhar um círculo com as dimensões apropriadas;
- ▶ Clique duas vezes com o botão esquerdo para adicionar 2 itens e respectivos erros
Nota: A ferramenta do modelo de medida, identifica por defeito uma trajetória da v. latente para o 1º item e as trajetórias dos erros para os itens, com o valor 1. Estes valores podem ser alterados posteriormente

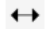


- ▶ Rode os itens para o lado esquerdo usando o botão 






- ▶ Proceda de forma semelhante para os restantes factores:

- ▶ Desenhe as trajetórias causais entre os factores usando a ferramenta 

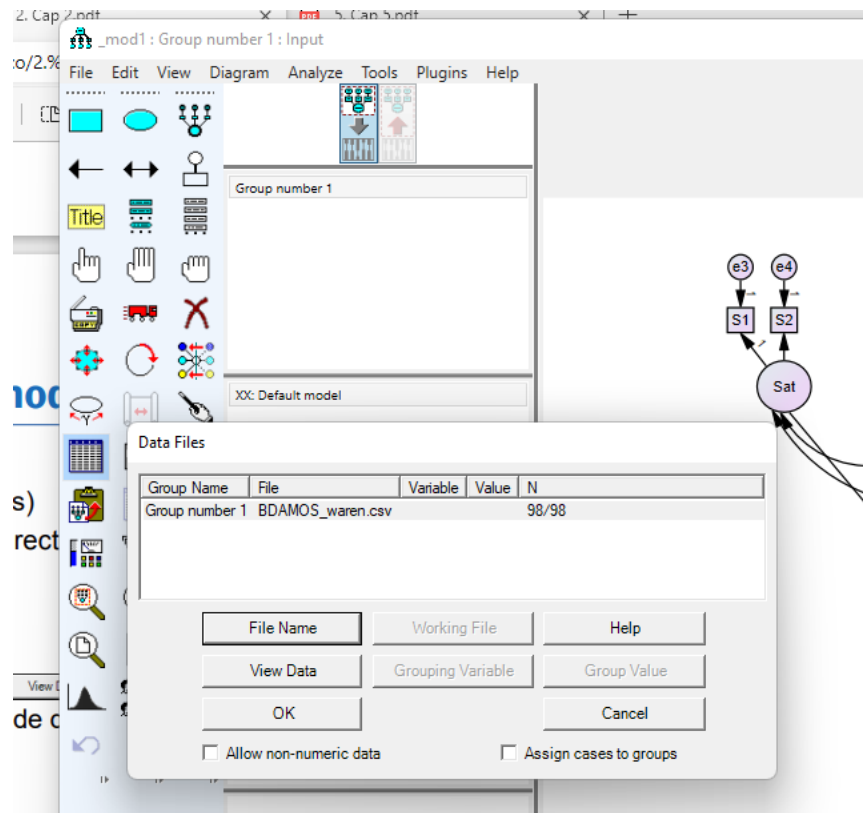
- ▶ Desenhe as Correlações entre os factores usando a ferramenta 

Nota: No AMOS text, as correlações entre factores latentes são assumidas por defeito, mas no AMOS graphics, WYSIWIG e portanto estas têm de ser desenhadas!...

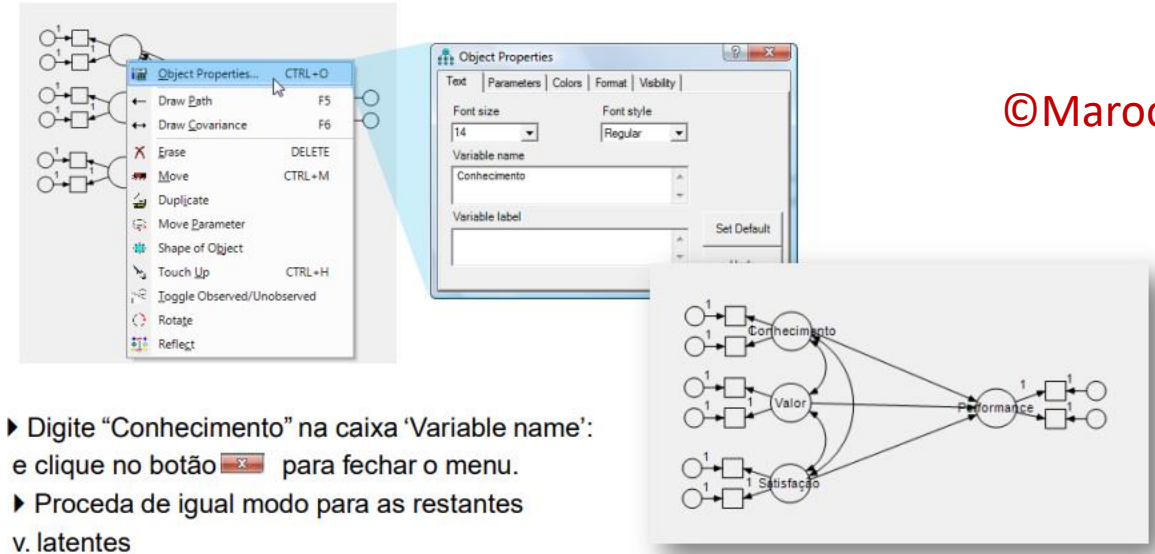


2. Identificar variáveis

➤ Abrir o ficheiro de dados




- ▶ Clique com o botão direito do rato em cada um dos círculos (v. latentes) e seleccione a opção 'Object Properties'




- ▶ Digite "Conhecimento" na caixa 'Variable name': e clique no botão para fechar o menu.
- ▶ Proceda de igual modo para as restantes v. latentes

- ▶ Clique no botão para listar as variáveis presentes na base de dados
- ▶ Clique em cada variável e, sem largar o botão esquerdo do rato, arraste-as até ao item correspondente:




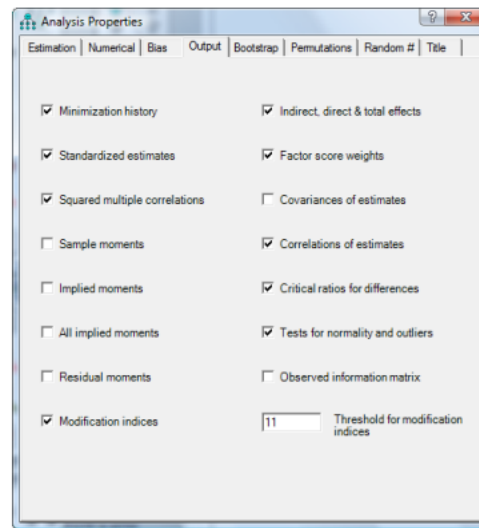
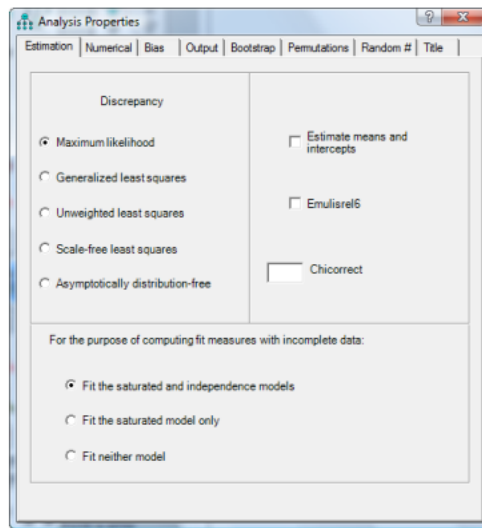
- ▶ Adicione o erro (Disturbance) da v.lantente 'Performance' (d1). Clique na ferramenta e clique em cima do 'circulo' da 'Performance':




4. Estimar o modelo


©Maroco

► Clique no botão  e especifique o método de análise e as opções de output, clicando nas patilhas 'Estimation' e 'Output' (as outras são irrelevantes na maioria das aplicações de AMEE)



► Clique, finalmente, no botão  para ajustar o modelo


Nesta fase, e se ainda não o fez anteriormente, o AMOS pedir-lhe-á para gravar o seu modelo gráfico, dando um nome ao ficheiro do tipo *.amw:



Digite aqui o nome do ficheiro

5. Analisar o output

Para visualizar o ficheiro de output completo (Wheaton.AmosOutput)

- ▶ Clique no botão  ou no menu 'View ▶ Text Output' (F10), para abrir o visualizador de outputs (AMOS output)

Nº de casas decimais dos valores no output

Espaçamento entre colunas

Árvore de Navegação do Output

Clicar no sinal [+] para expandir a árvore de navegação e visualizar o output na janela de output

Área de Output

e.g. Coeficientes de trajetória e pesos factoriais (Regression weights):

Trajectórias

Estimativas do coeficiente

Estimativas dos SE da estimativas

*C.R. Critical Ratios
 $Z = Est/SE \sim N(0,1)$*

*P-value associado a
 $Z = Est/SE \sim N(0,1)$*

Amos Output

Regression Weights: (Group number 1 - Default model)

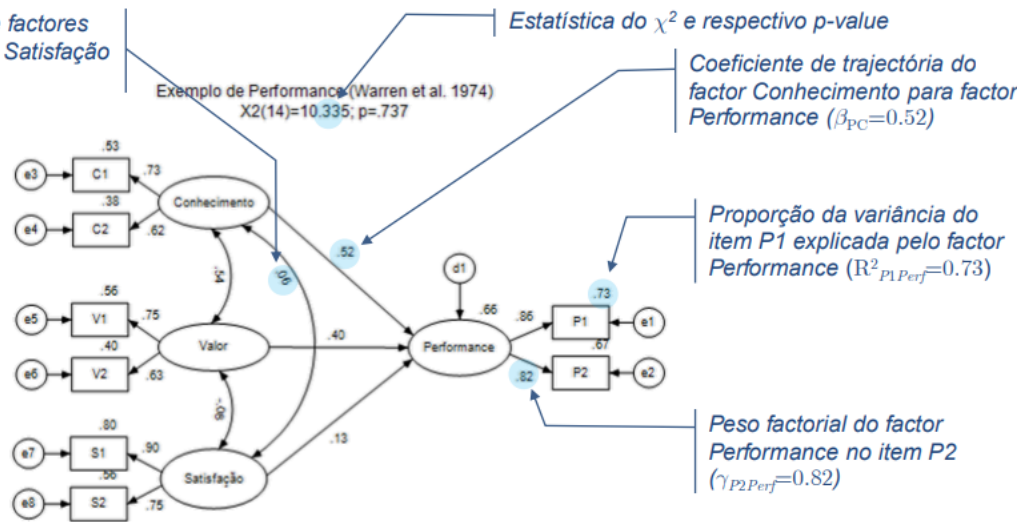
		Estimate	S.E.	C.R.	P	Label
Performance	<--- Valor	.231	.100	2.300	.021	par_5
Performance	<--- Conhecimento	.494	.177	2.786	.005	par_6
Performance	<--- Satisfação	.077	.061	1.259	.208	par_9
C2	<--- Conhecimento	1.000				
C1	<--- Conhecimento	1.463	.344	4.252	***	par_1
V2	<--- Valor	1.000				
V1	<--- Valor	1.311	.318	4.128	***	par_2
S2	<--- Satisfação	1.000				
S1	<--- Satisfação	1.263	.699	1.806	.071	par_3
P1	<--- Performance	1.000				
P2	<--- Performance	.867	.116	7.450	***	par_4

5. Analisar os outputs

Os resultados da análise podem visualizar-se rapidamente na área de desenho, ou extensivamente no ficheiro de output.

Standardized estimates

Correlação entre factores
Conhecimento e Satisfação
($R_{ConhSat}=0.06$)



Para visualizar o ficheiro de output completo (Wheaton.AmosOutput)

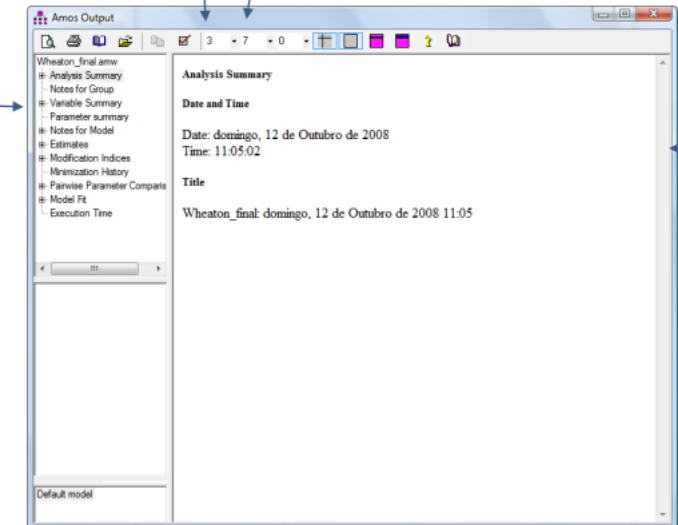
- ▶ Clique no botão ou no menu 'View ▶ Text Output' (F10), para abrir o visualizador de outputs (AMOS output)

Nº de casas decimais dos valores no output

Espaçamento entre colunas

Árvore de Navegação do Output

Clicar no sinal [+] para expandir a árvore de navegação e visualizar o output na janela de output



Área de Output

5. Analisar os outputs

e.g. Coeficientes de trajetória e pesos factoriais (Regression weights):

Trajectórias

Estimativas do coeficiente
Estimativas dos SE da estimativas

C.R. Critica
 $Z = Est/SE$

P-value as
 $Z = Est/SE$

		Estimate	S.E.	C.R.	P	Label
Performance <---	Valor	.231	.100	2.300	.021	par_5
Performance <---	Conhecimento	.494	.177	2.786	.005	par_6
Performance <---	Satisfação	.077	.061	1.259	.208	par_9
C2 <---	Conhecimento	1.000				
C1 <---	Conhecimento	1.463	.344	4.252	***	par_1
V2 <---	Valor	1.000				
V1 <---	Valor	1.311	.318	4.128	***	par_2
S2 <---	Satisfação	1.000				
S1 <---	Satisfação	1.263	.699	1.806	.071	par_3
P1 <---	Performance	1.000				
P2 <---	Performance	.867	.116	7.450	***	par_4

e.g. Índices da qualidade do ajustamento (Model Fit):

É possível clicar em todos os elemento do output e chamar o "help" do AMOS

Model Fit Summary

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	22	10.335	14	.737	.738
Saturated model	36	.000	0		
Independence model	8	243.768	28	.000	8.706

RMR, GFI

Model	RMR	GFI	AGFI	PGFI
Default model	.003	.975	.935	.379
Saturated model	.000	1.000		
Independence model	.023	.57		

Baseline Comparisons

Model	NFI	RFI	IFI	TLI	CFI
Default model	.958	.915	1.016	1.034	1.000
Saturated model	1.000		1.000	1.000	
Independence model	.000	.000	.000	.000	.000

GFI value
GFI = .975 for the Default model model

Amos Reference Guide

GFI
The GFI (goodness of fit index) was devised by Jöreskog and Sörbom (1984) for ML and ML estimation, and generalized to other estimation criteria by Tabachnick and Fidell (1985). The GFI is given by

$$GFI = 1 - \frac{\hat{F}}{\hat{F}_0}$$

where \hat{F} is the minimum value of the discrepancy function defined in Appendix B and \hat{F}_0 is obtained by evaluating F with $\sum(\xi) = 0, \xi = 1, 2, \dots, G$. An exception has to be made for maximum likelihood estimation, since (D2) in Appendix B is not defined for $\sum(\xi) = 0$. For the purpose of computing GFI in the case of maximum likelihood estimation, $f(\Sigma^{(s)}; S^{(s)})$ in Appendix B is calculated as

$$f(\Sigma^{(s)}; S^{(s)}) = \frac{1}{2} \text{tr} \left[\mathbf{K}^{(s)^{-1}} (S^{(s)} - \Sigma^{(s)})^2 \right]$$

with $\mathbf{K}^{(s)} = \Sigma^{(s)}(\hat{\gamma}_{ML})$, where $\hat{\gamma}_{ML}$ is the maximum likelihood estimate of γ .

GFI is less than or equal to 1. A value of 1 indicates a perfect fit. Use the [GFI text macro](#) to display GFI on a path diagram.