

ANÁLISE DE DADOS EM GRH

Aula 7:

'Que fatores explicam a variação nos salários na organização?

Validação de Modelos de Regressão Linear

Docente: Daniela Craveiro
dcraveiro@iseg.ulisboa.pt

ANÁLISE DE DADOS EM GRH

- Na Aula Anterior
 - Aprendemos a implementar e interpretar o resultado de um modelo de regressão linear
- Objetivos da Aula
 - Parte Teórica
 - Perceber qual a necessidade de fazermos diagnósticos aos pressupostos do nosso modelo de regressão
 - Saber quais são os pressupostos do modelo de regressão linear
 - Saber como, com a ajuda de gráficos e testes estatísticos, podemos conferir se os pressupostos do modelo estão a ser cumpridos
 - Parte Prática
 - Saber implementar os estudo dos pressupostos do modelo no SPSS

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">• Análise gráfica (Matriz de Dispersão, por exemplo)

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

	PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I	Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">• Análise gráfica (Matriz de Dispersão, por exemplo)
II	Normalidade da Distribuição dos Erros	Os erros seguem uma distribuição normal.	<ul style="list-style-type: none">• Análise de Resíduos• Gráfico de Q-Q

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

	PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I	Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">• Análise gráfica (Matriz de Dispersão, por exemplo)
II	Normalidade da Distribuição dos Erros	Os erros seguem uma distribuição normal.	<ul style="list-style-type: none">• Análise de Resíduos• Gráfico de Q-Q
III	Média Condisional Zero dos Erros	O termo de erro aleatório tem valor esperado igual a zero.	<ul style="list-style-type: none">• Análise de Resíduos

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

	PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I	Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">• Análise gráfica (Matriz de Dispersão, por exemplo)
II	Normalidade da Distribuição dos Erros	Os erros seguem uma distribuição normal.	<ul style="list-style-type: none">• Análise de Resíduos• Gráfico de Q-Q
III	Média Condisional Zero dos Erros	O termo de erro aleatório tem valor esperado igual a zero.	<ul style="list-style-type: none">• Análise de Resíduos
IV	Homocedasticidade (ou Igual Variância)	A distribuição dos erros apresenta uma variância constante (hipótese da homocedasticidade).	<ul style="list-style-type: none">• Análise de Resíduos

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

	PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I	Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">Análise gráfica (Matriz de Dispersão, por exemplo)
II	Normalidade da Distribuição dos Erros	Os erros seguem uma distribuição normal.	<ul style="list-style-type: none">Análise de ResíduosGráfico de Q-Q
III	Média Condicional Zero dos Erros	O termo de erro aleatório tem valor esperado igual a zero.	<ul style="list-style-type: none">Análise de Resíduos
IV	Homocedasticidade (ou Igual Variância)	A distribuição dos erros apresenta uma variância constante (hipótese da homocedasticidade).	<ul style="list-style-type: none">Análise de Resíduos
V	Independência dos Erros	Os erros não estão correlacionados, i.e., o valor de um erro não depende de qualquer outro erro.	<ul style="list-style-type: none">Dublin-Watson

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

	PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I	Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">Análise gráfica (Matriz de Dispersão, por exemplo)
II	Normalidade da Distribuição dos Erros	Os erros seguem uma distribuição normal.	<ul style="list-style-type: none">Análise de ResíduosGráfico de Q-Q
III	Média Condicional Zero dos Erros	O termo de erro aleatório tem valor esperado igual a zero.	<ul style="list-style-type: none">Análise de Resíduos
IV	Homocedasticidade (ou Igual Variância)	A distribuição dos erros apresenta uma variância constante (hipótese da homocedasticidade).	<ul style="list-style-type: none">Análise de Resíduos
V	Independência dos Erros	Os erros não estão correlacionados, i.e., o valor de um erro não depende de qualquer outro erro.	<ul style="list-style-type: none">Dublin-Watson
VI	Ausência de multicolinearidade perfeita	As variáveis independentes não estão perfeitamente correlacionadas entre si.	<ul style="list-style-type: none">Diagnósticos de Colinearidade

ANÁLISE DE DADOS EM GRH

Pressupostos do modelo de regressão

	PRESSUPOSTOS	DEFINIÇÃO	FORMA DE VALIDAÇÃO
I	Linearidade	O efeito das variáveis independentes na variável dependente é linear e aditivo.	<ul style="list-style-type: none">Análise gráfica (Matriz de Dispersão, por exemplo)
II	Normalidade da Distribuição dos Erros	Os erros seguem uma distribuição normal.	<ul style="list-style-type: none">Análise de ResíduosGráfico de Q-Q
III	Média Condicional Zero dos Erros	O termo de erro aleatório tem valor esperado igual a zero.	<ul style="list-style-type: none">Análise de Resíduos
IV	Homocedasticidade (ou Igual Variância)	A distribuição dos erros apresenta uma variância constante (hipótese da homocedasticidade).	<ul style="list-style-type: none">Análise de Resíduos
V	Independência dos Erros	Os erros não estão correlacionados, i.e., o valor de um erro não depende de qualquer outro erro.	<ul style="list-style-type: none">Dublin-Watson
VI	Ausência de multicolinearidade perfeita	As variáveis independentes não estão perfeitamente correlacionadas entre si.	<ul style="list-style-type: none">Diagnósticos de Colinearidade
VII	Ausência de Observações Influentes	Não existem observações que tenham uma influência anormal nos resultados do modelo.	<ul style="list-style-type: none">Cook's Distance

ANÁLISE DE DADOS EM GRH

E qual é o problema se estes pressupostos não se verificarem?

- Os intervalos de confiança ou os p-values podem estar a ser subestimados (i.e. mais pequenos do que na realidade são) ...

ou seja: estamos a atribuir significância estatística a uma estimativa que na realidade não a terá!

ANÁLISE DE DADOS EM GRH

Como podemos saber se estes pressupostos estão a ser cumpridos?

Validação do Modelo de Regressão Linear

1. *Estimar o modelo de regressão com os diagnósticos*
2. *Avaliação do Pressuposto II: Normalidade da Distribuição dos Erros*
3. *Avaliação do Pressuposto III: Média Condicional Zero dos Erros*
4. *Avaliação do Pressuposto IV: Homocedasticidade*
4. *Avaliação do Pressuposto V: Independência dos Erros*
5. *Avaliação do Pressuposto VI: Ausência de Multicolinearidade Perfeita*
6. *Avaliação do Pressuposto VII: Ausência de Observações Influentes*

ANÁLISE DE DADOS EM GRH

Validação do Modelo de Regressão Linear

1. Estimar o modelo de regressão com os diagnósticos

Diagnósticos

- Selecionar 'Analizar' / 'Regressão' / 'Linear'
- Selecionar a variável 'y_wage2'
- Colocar na caixa 'Dependente'

Exercício: Colocar as variáveis 'sex_female', 'experience' e 'evaluation' na caixa 'Independente(s)'

A

B

C

The image consists of two screenshots of the IBM SPSS Statistics software interface.

Screenshot A: Shows the main menu bar with 'Analisar' (Analyze) highlighted. Below the menu, there is a list of statistical procedures. The 'Regressão' (Regression) option is selected, and its sub-options 'Linear...' and 'Curva de estimação...' are visible. A red circle labeled 'A' highlights the 'Analisar' menu item.

Screenshot B: Shows the 'Regressão Linear' (Linear Regression) dialog box. On the left is a list of variables: start_age, experience, y_wage, department, hrs_week, hearing, skin, back, muscle_upper, muscle_lower, headache, injury, anxiety, fatigue, absent_nr, workcond_sat, evaluation, and y_wage2. A red circle labeled 'B' highlights the 'y_wage2' variable in this list. The 'Dependente:' field on the right is empty, indicated by a red circle labeled 'C'.

Screenshot C: Shows the same 'Regressão Linear' dialog box. The 'Dependente:' field now contains 'y_wage2', indicated by a red circle labeled 'C'. The 'Independentes(s):' field is empty, indicated by a red circle labeled 'B'.

Diagnósticos

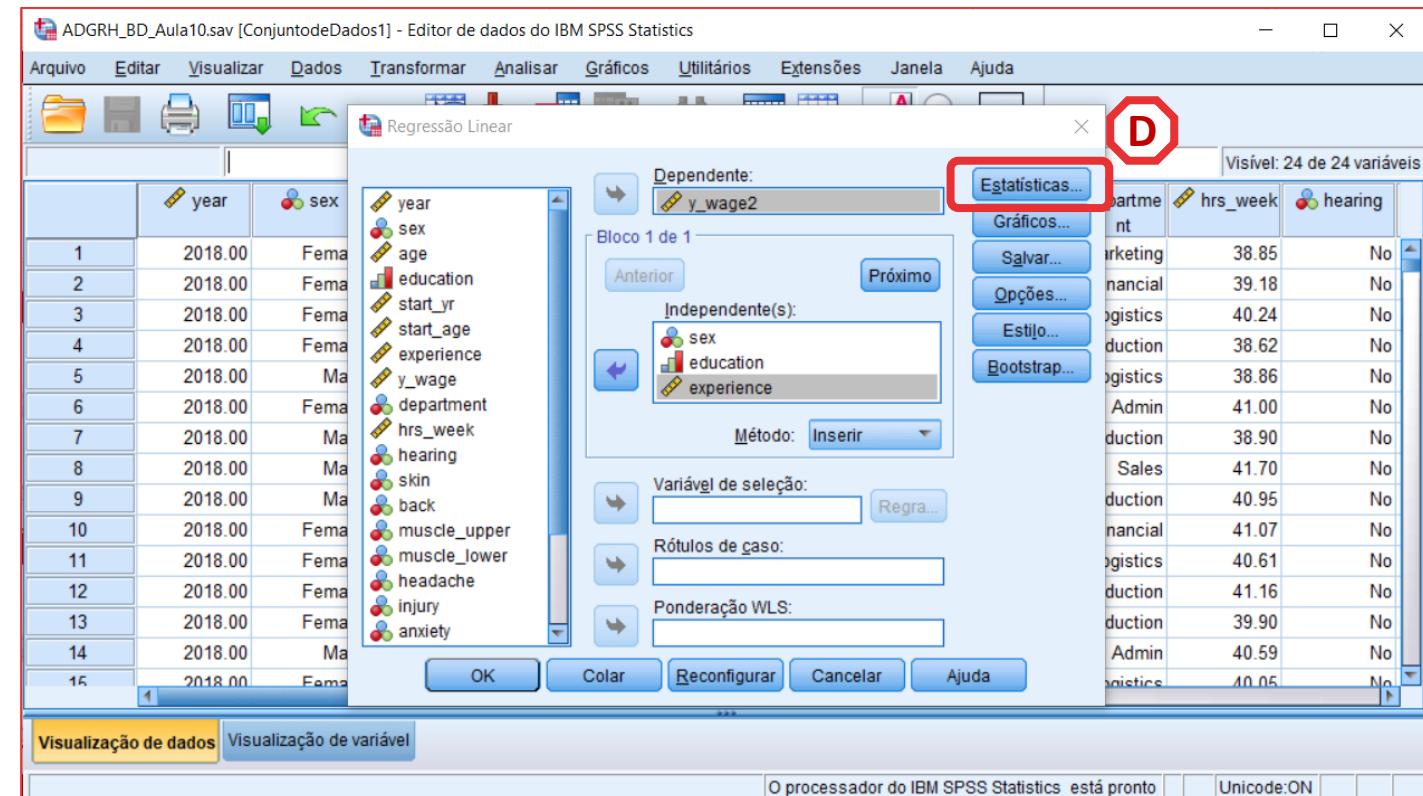
- Selecionar 'Analizar' / 'Regressão' / 'Linear'
- Selecionar a variável 'y_wage2'
- Colocar na caixa 'Dependente'
Exercício: Colocar as variáveis 'sex_female', 'experience' e 'evaluation' na caixa 'Independente(s)'
- Selecionar botão 'Estatísticas'

A

B

C

D



Diagnósticos

- Selecionar 'Analizar' / 'Regressão' / 'Linear'
- Selecionar a variável 'y_wage2'
- Colocar na caixa 'Dependente'
Exercício: Colocar as variáveis 'sex_female', 'experience' e 'evaluation' na caixa 'Independente(s)'
- Selecionar botão 'Estatísticas'
- Selecionar 'Estimativas'

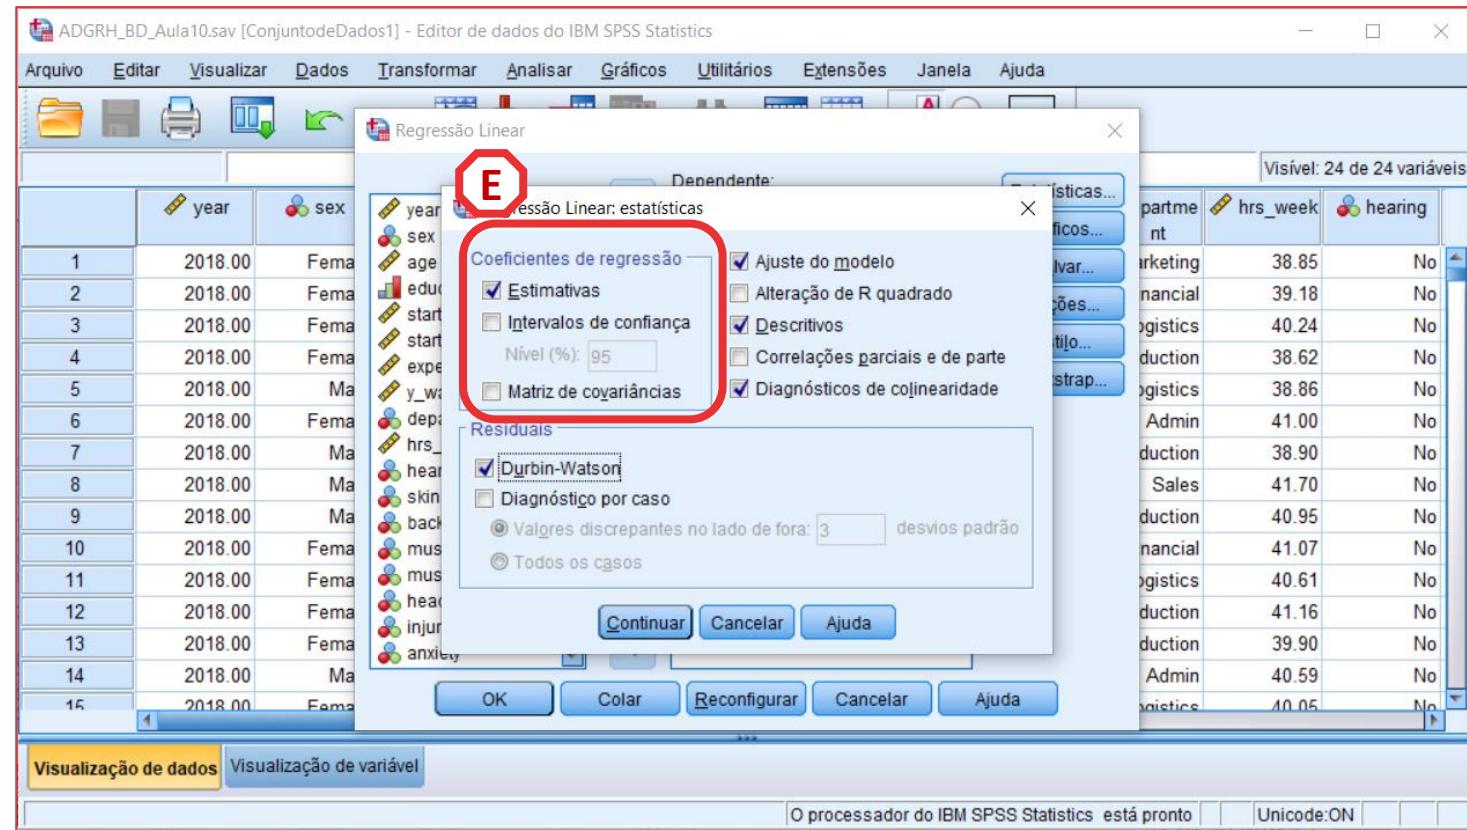
A

B

C

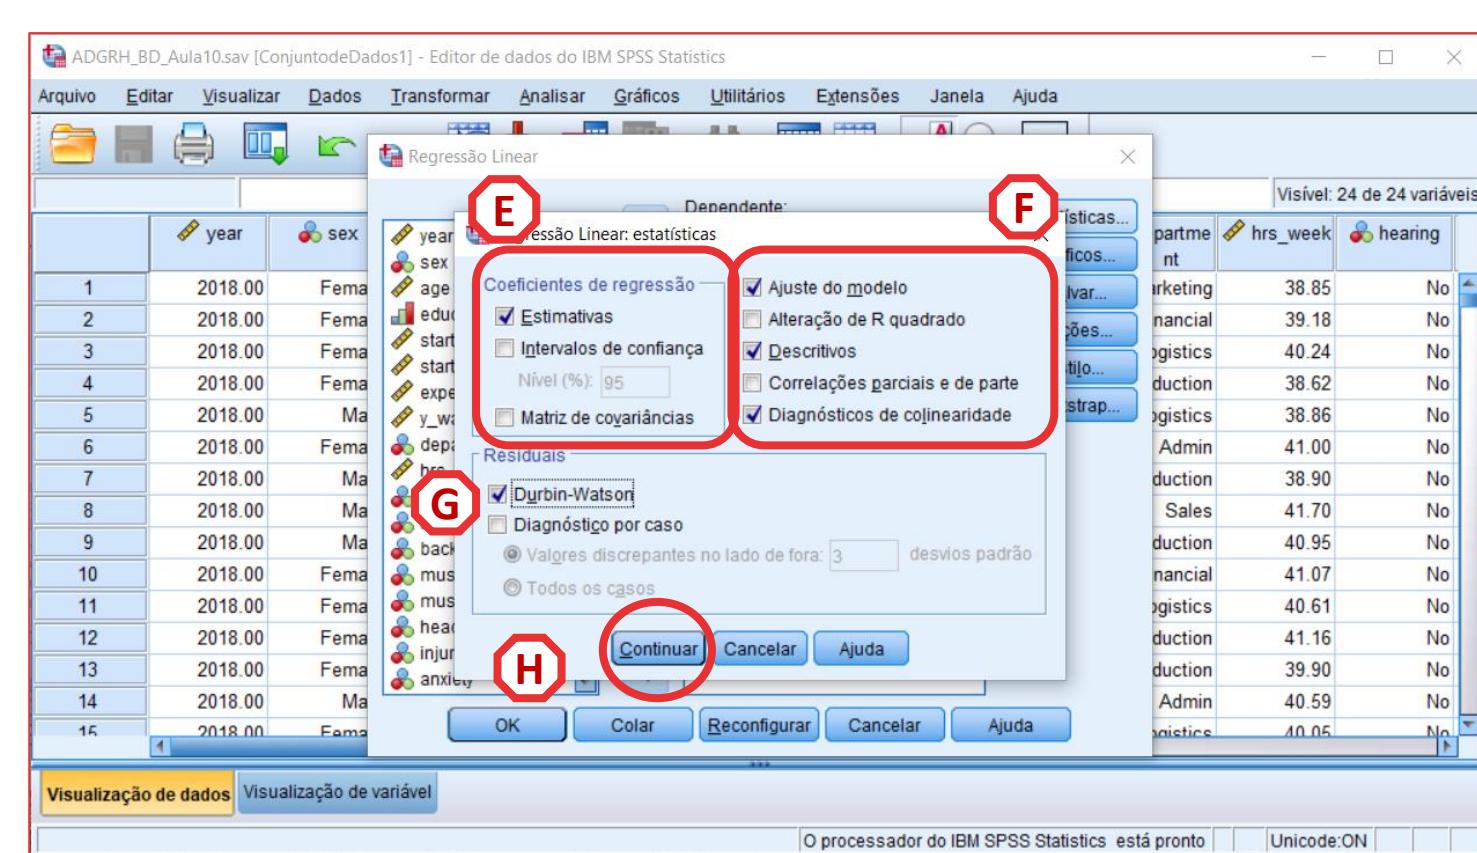
D

E



Diagnósticos

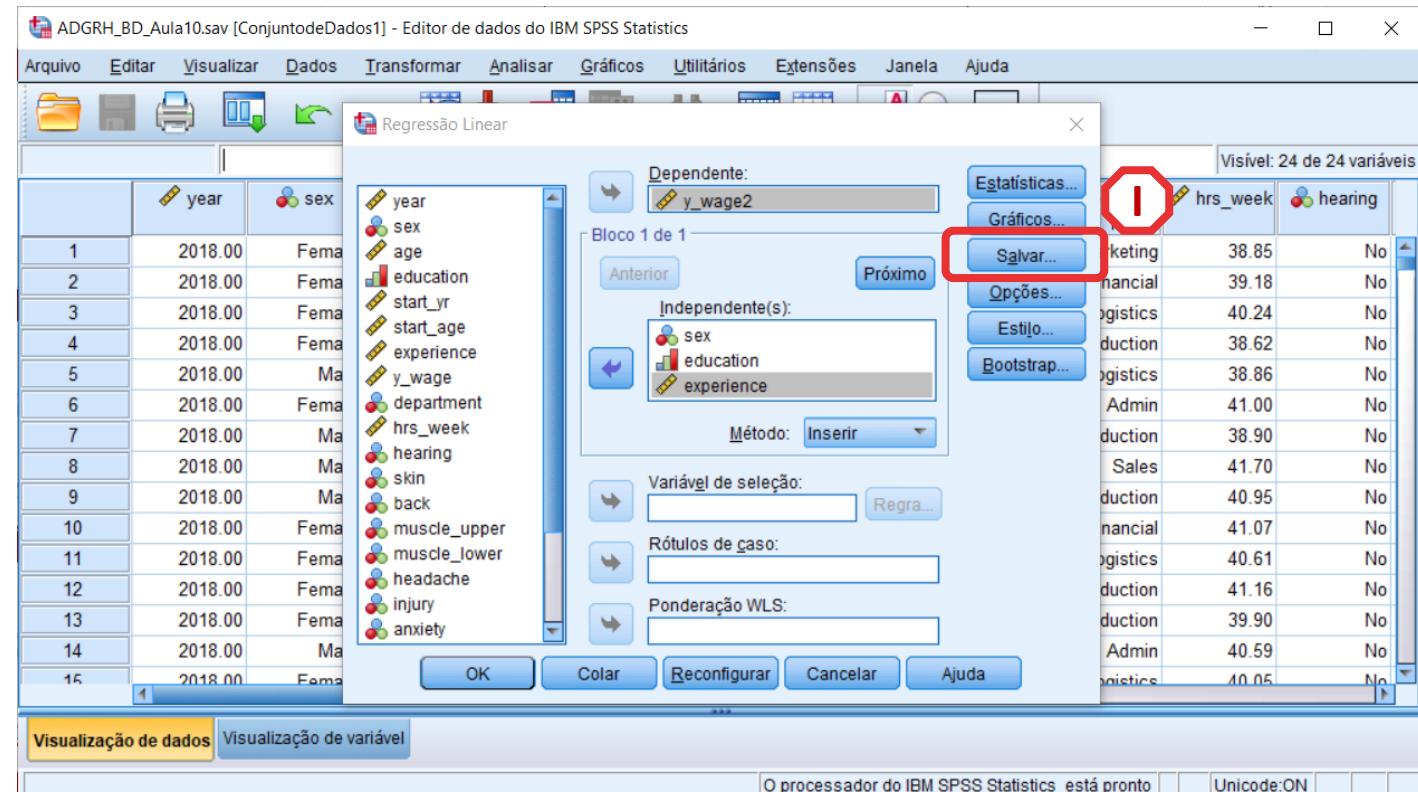
- Selecionar ‘Ajuste do modelo’ F
- Selecionar ‘Descritivos’ F
- Selecionar ‘Diagnósticos de colinearidade’ F
- Selecionar ‘Dublin-Watson’ G
- Selecionar ‘Continuar’ H



Diagnósticos

- Selecionar botão ‘Salvar’

I

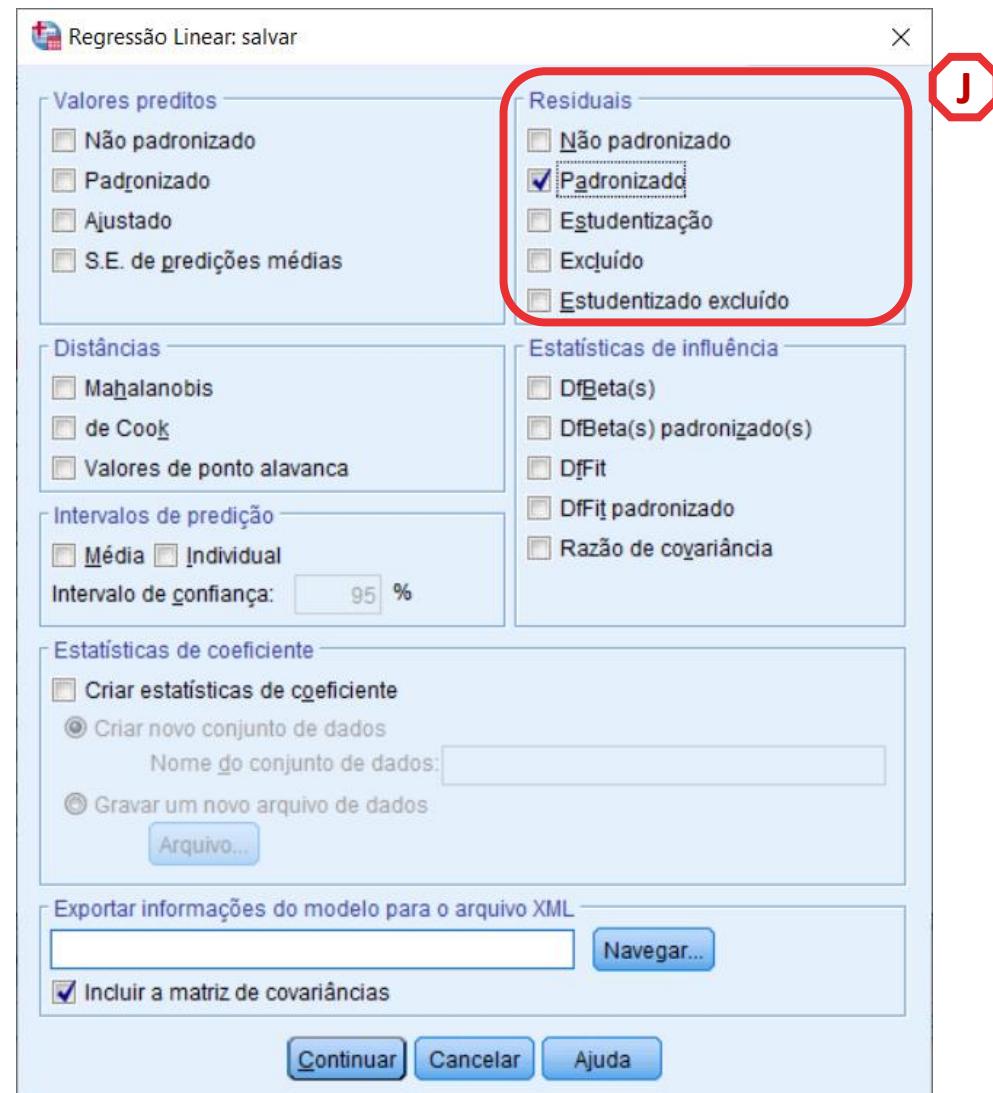


Diagnósticos

- Selecionar botão ‘Salvar’
- Selecionar ‘Padronizado’

I

J



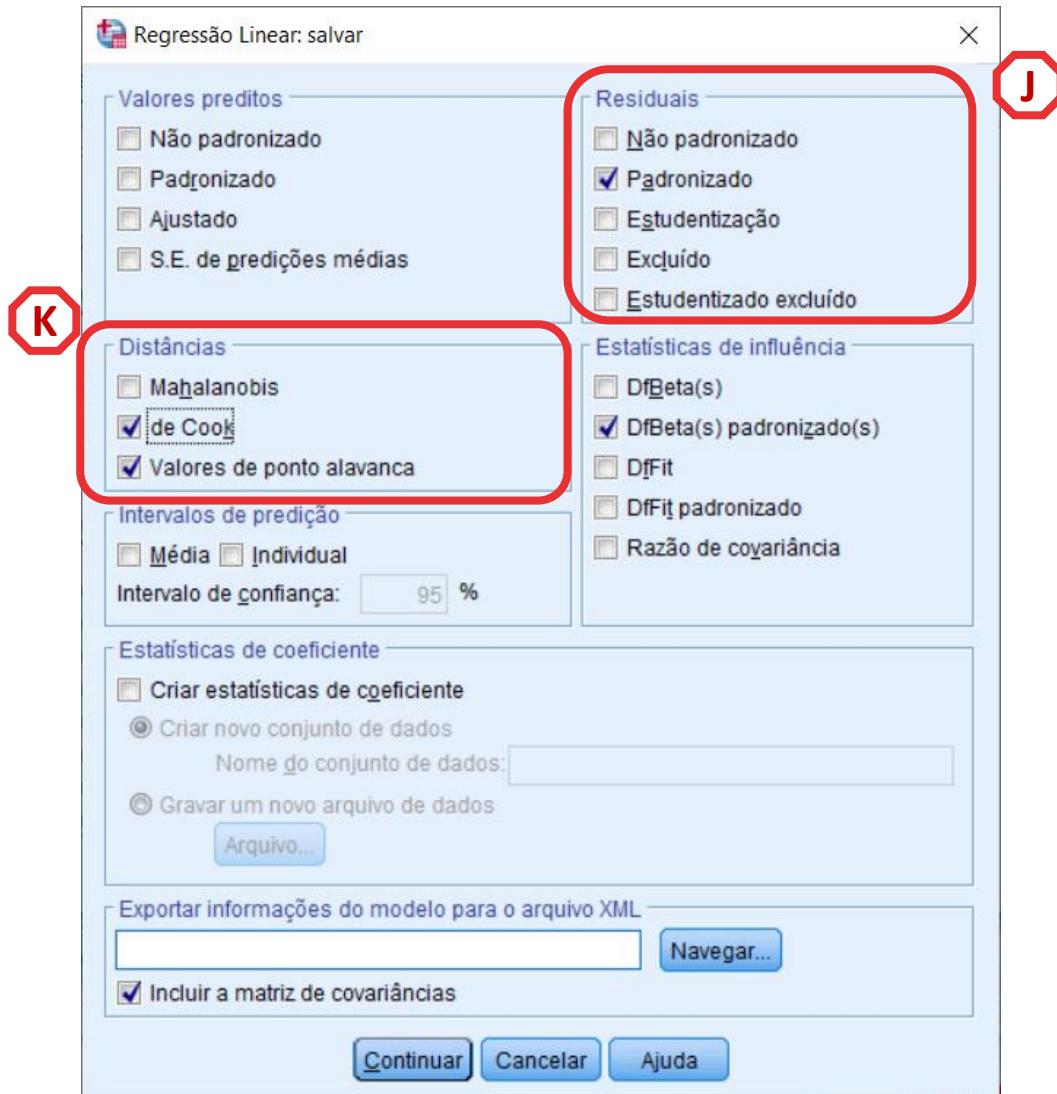
Diagnósticos

- **Selecionar botão ‘Salvar’**
- **Selecionar ‘Padronizado’**
- **Selecionar ‘de Cook’ e ‘Valores de ponto alavancado’**

I

J

K



Diagnósticos

- **Selecionar botão ‘Salvar’**
- **Selecionar ‘Padronizado’**
- **Selecionar ‘de Cook’ e ‘Valores de ponto alavancado’**
- **Selecionar ‘DfBeta(s) padronizado(s)**
- **Selecionar ‘Continuar’/ ‘OK’**

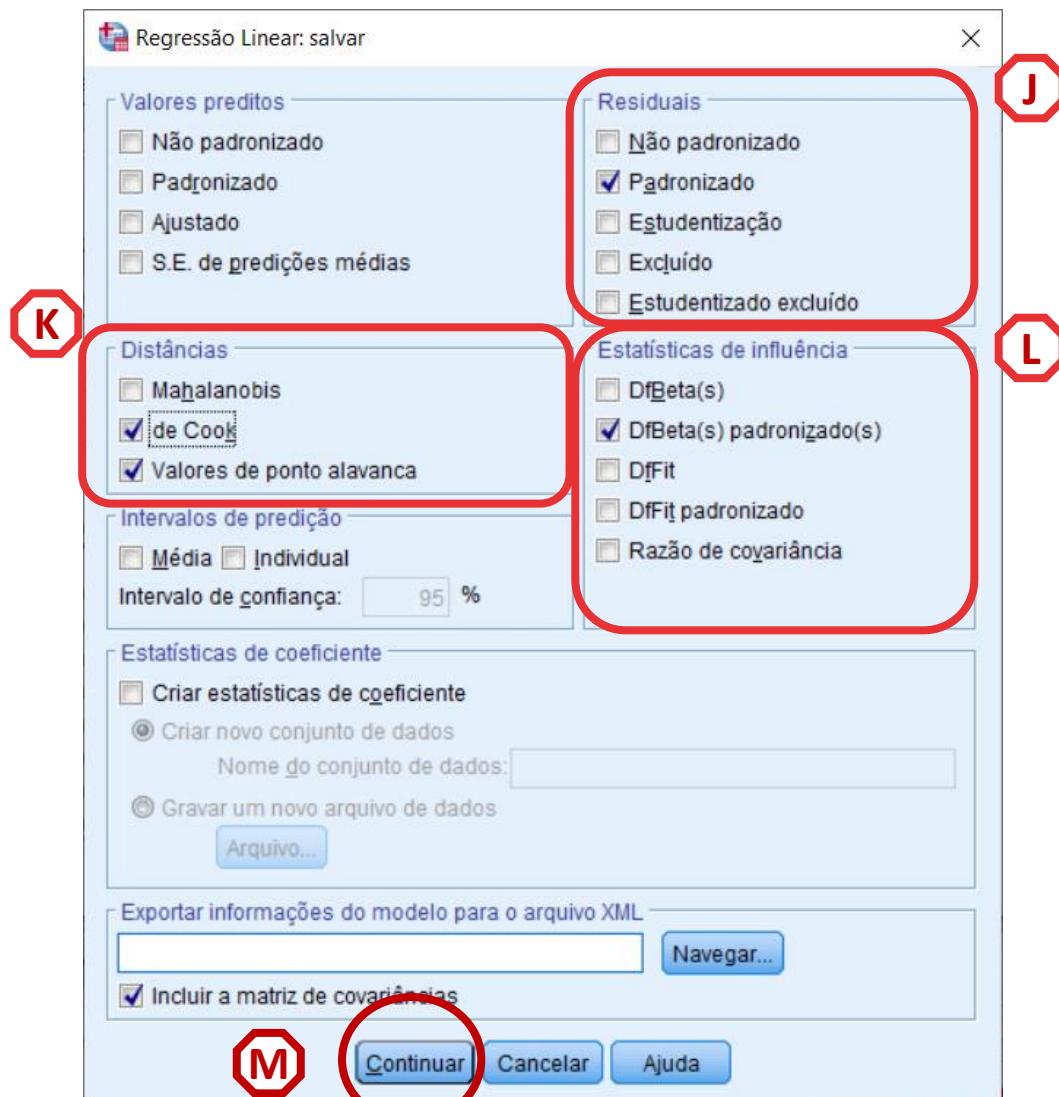
I

J

K

L

M



Diagnósticos

- Os resultados são publicados no ‘Visualizador de Resultados’

The screenshot shows the 'Saída1 [Documento1] - Visualizador do IBM SPSS Statistics' window. The menu bar includes Arquivo, Editar, Visualizar, Dados, Transformar, Inserir, Formatar, Analisar, Gráficos, Utilitários, Extensões, Janela, and Ajuda. The toolbar includes icons for file operations, search, and various analysis tools. The left pane displays a tree view of the results:

- Saída
 - Log
 - Regressão
 - Título
 - Observações
 - Estatística Descritiva
 - Correlações
 - Variáveis Inseridas/Removidas
 - Resumo do modelo
 - ANOVA
 - Coefficientes
 - Diagnóstico de colinearidade
 - Estatísticas de resíduos
 - Gráficos
 - Título
 - *zresid por *zpred Gráfico de Dispe

The right pane contains the following sections:

- REGRESSION**

```
/DESCRIPTIVES MEAN STDDEV CORR SIG N  
/MISSING LISTWISE  
/STATISTICS COEFF OUTS R ANOVA COLLIN TOL  
/CRITERIA=PIN(.05) POUT(.10)  
/NOORIGIN  
/DEPENDENT y_wage2  
/METHOD=ENTER sex education experience  
/SCATTERPLOT(*ZRESID,*ZPRED)  
/RESIDUALS DURBIN  
/SAVE LEVER ZRESID SDBETA.
```
- Regressão**
- Estatística Descritiva**

	Média	Erro Desvio	N
y_wage2	25405.6559	8132.60405	4858
sex	1.50	.500	4858
education	3.00	1.411	4858
experience	10.6015	5.71732	4858
- Correlações**

	y_wage2	sex	education	experience	
Correlação de Pearson	y_wage2	1.000	-.250	.238	.224
	sex	-.250	1.000	-.010	.014
	education	.238	-.010	1.000	-.023
	experience	.224	.014	-.023	1.000
Sig. (1 extremidade)	y_wage2	.	.000	.000	.000
	sex	.000	.	.245	.170
	education	.000	.245	.	.054
	experience	.000	.170	.054	.

Diagnósticos

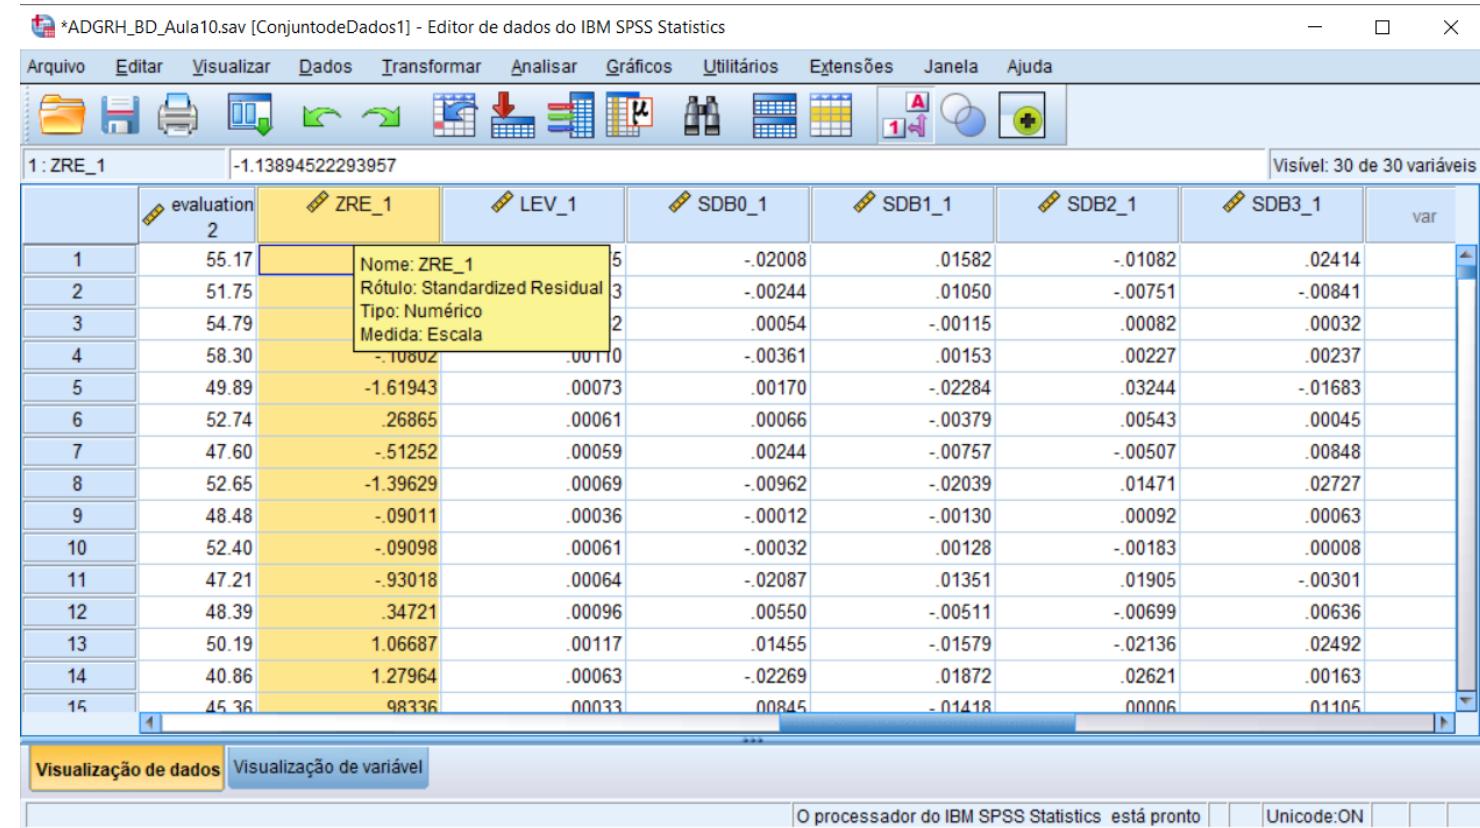
- Quando instruímos o SPSS para produzir os diagnósticos, é criado um conjunto variáveis

	evaluation_2	ZRE_1	COO_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1	SDB3_1
1	55.17	-1.13895	.00031	.00075	-.02008	.01582	-.01082	.02414	
2	51.75	-.73316	.00009	.00043	-.00244	.01050	-.00751	-.00841	
3	54.79	.08094	.00000	.00032	.00054	-.00115	.00082	.00032	
4	58.30	-.10802	.00000	.00110	-.00361	.00153	.00227	.00237	
5	49.89	-1.61943	.00061	.00073	.00170	-.02284	.03244	-.01683	
6	52.74	.26865	.00001	.00061	.00066	-.00379	.00543	.00045	
7	47.60	-.51252	.00005	.00059	.00244	-.00757	-.00507	.00848	
8	52.65	-1.39629	.00044	.00069	-.00962	-.02039	.01471	.02727	
9	48.48	-.09011	.00000	.00036	-.00012	-.00130	.00092	.00063	
10	52.40	-.09098	.00000	.00061	-.00032	.00128	-.00183	.00008	
11	47.21	-.93018	.00018	.00064	-.02087	.01351	.01905	-.00301	
12	48.39	.34721	.00004	.00096	.00550	-.00511	-.00699	.00636	
13	50.19	1.06687	.00039	.00117	.01455	-.01579	-.02136	.02492	
14	40.86	1.27964	.00034	.00063	-.02269	.01872	.02621	.00163	
15	45.36	98336	.00013	.00033	.00845	-.01418	.00006	.01105	

ANÁLISE DE DADOS EM GRH

Diagnósticos

- Quando instruímos o SPSS para produzir os diagnósticos, é criado um conjunto variáveis
 - Uma variável com os ‘Resíduos Padronizados’ da variável dependente (ZRE_1) para cada observação



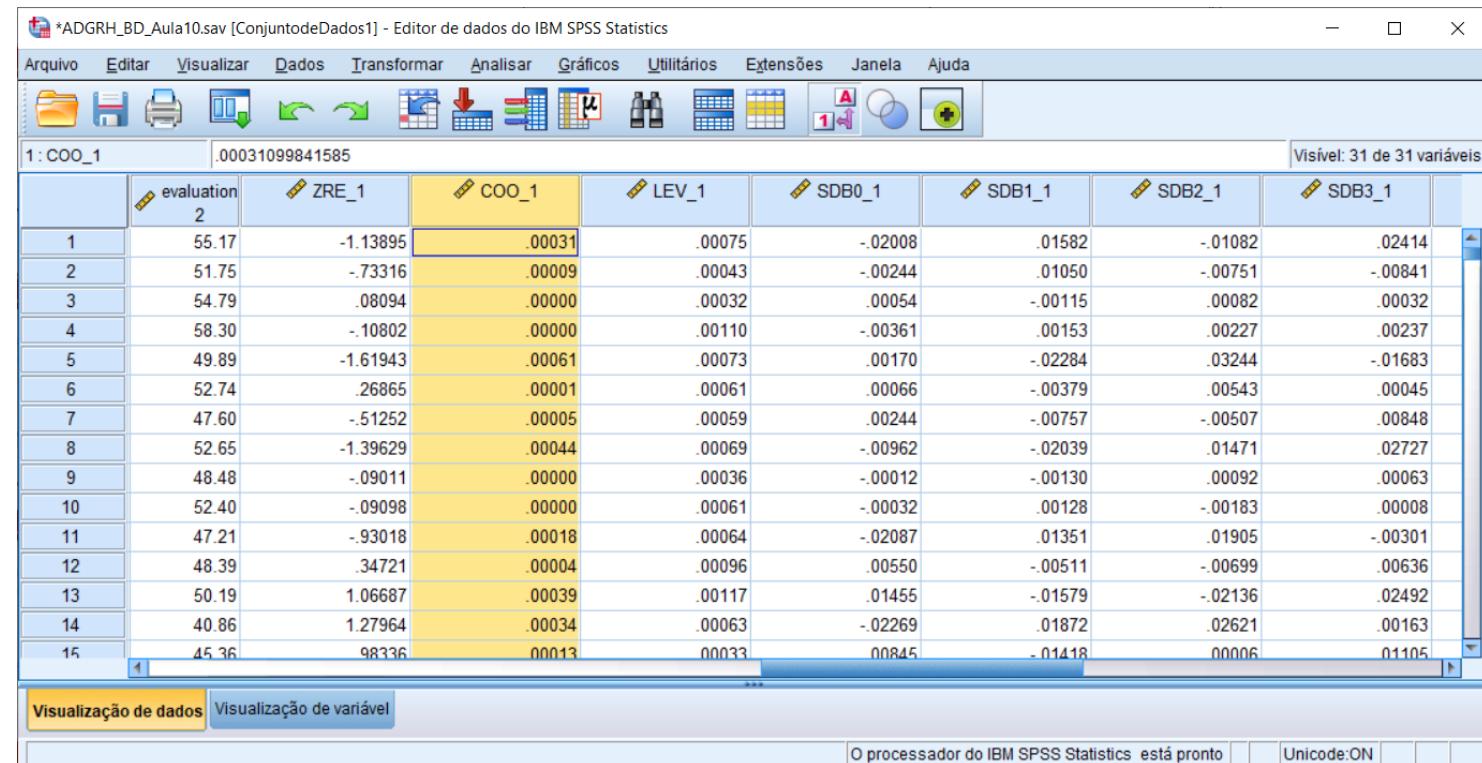
	evaluation 2	ZRE_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1	var
1	55.17							
2	51.75							
3	54.79							
4	58.30							
5	49.89	-1.61943						
6	52.74	.26865						
7	47.60	-.51252						
8	52.65	-1.39629						
9	48.48	-.09011						
10	52.40	-.09098						
11	47.21	-.93018						
12	48.39	.34721						
13	50.19	1.06687						
14	40.86	1.27964						
15	45.36	98336						

ANÁLISE DE DADOS EM GRH

Diagnósticos

- Quando instruímos o SPSS para produzir os diagnósticos, é criado um conjunto variáveis

- Uma variável com os 'Resíduos Padronizados' da variável dependente (ZRE_1) para cada observação
- Uma variável que mede a distância de Cook associada a cada observação (COO_1)

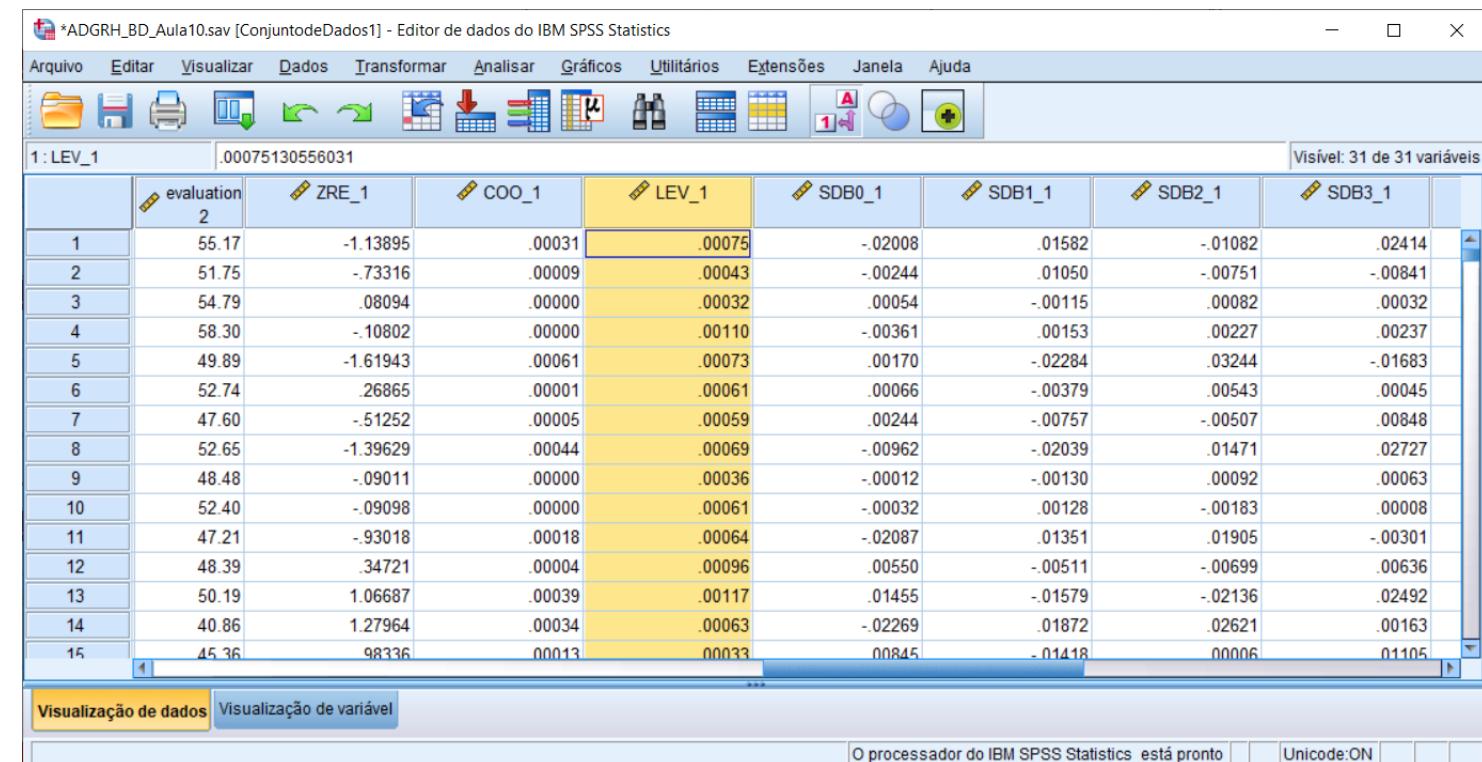


	evaluation_2	ZRE_1	COO_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1		
1	55.17	-1.13895	.00031	.00075	-.02008	.01582	-.01082	.02414		
2	51.75	-.73316	.00009	.00043	-.00244	.01050	-.00751	-.00841		
3	54.79	.08094	.00000	.00032	.00054	-.00115	.00082	.00032		
4	58.30	-.10802	.00000	.00110	-.00361	.00153	.00227	.00237		
5	49.89	-1.61943	.00061	.00073	.00170	-.02284	.03244	-.01683		
6	52.74	.26865	.00001	.00061	.00066	-.00379	.00543	.00045		
7	47.60	-.51252	.00005	.00059	.00244	-.00757	-.00507	.00848		
8	52.65	-1.39629	.00044	.00069	-.00962	-.02039	.01471	.02727		
9	48.48	-.09011	.00000	.00036	-.00012	-.00130	.00092	.00063		
10	52.40	-.09098	.00000	.00061	-.00032	.00128	-.00183	.00008		
11	47.21	-.93018	.00018	.00064	-.02087	.01351	.01905	-.00301		
12	48.39	.34721	.00004	.00096	.00550	-.00511	-.00699	.00636		
13	50.19	1.06687	.00039	.00117	.01455	-.01579	-.02136	.02492		
14	40.86	1.27964	.00034	.00063	-.02269	.01872	.02621	.00163		
15	45.36	98336	.00013	.00033	.00845	-.01418	00006	01105		

ANÁLISE DE DADOS EM GRH

Diagnósticos

- Quando instruímos o SPSS para produzir os diagnósticos, é criado um conjunto variáveis
 - Uma variável com os 'Resíduos Padronizados' da variável dependente (**ZRE_1**) para cada observação
 - Uma variável que mede a distância de Cook associada a cada observação (**COO_1**)
 - Uma variável que mede influência relativa de cada observação no ajuste do modelo (**LEV_1**).



	evaluation_2	ZRE_1	COO_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1	
1	55.17	-1.13895	.00031	.00075	-.02008	.01582	-.01082	.02414	
2	51.75	-.73316	.00009	.00043	-.00244	.01050	-.00751	-.00841	
3	54.79	.08094	.00000	.00032	.00054	-.00115	.00082	.00032	
4	58.30	-.10802	.00000	.00110	-.00361	.00153	.00227	.00237	
5	49.89	-1.61943	.00061	.00073	.00170	-.02284	.03244	-.01683	
6	52.74	.26865	.00001	.00061	.00066	-.00379	.00543	.00045	
7	47.60	-.51252	.00005	.00059	.00244	-.00757	-.00507	.00848	
8	52.65	-1.39629	.00044	.00069	-.00962	-.02039	.01471	.02727	
9	48.48	-.09011	.00000	.00036	-.00012	-.00130	.00092	.00063	
10	52.40	-.09098	.00000	.00061	-.00032	.00128	-.00183	.00008	
11	47.21	-.93018	.00018	.00064	-.02087	.01351	.01905	-.00301	
12	48.39	.34721	.00004	.00096	.00550	-.00511	-.00699	.00636	
13	50.19	1.06687	.00039	.00117	.01455	-.01579	-.02136	.02492	
14	40.86	1.27964	.00034	.00063	-.02269	.01872	.02621	.00163	
15	45.36	98336	.00013	.00033	.00845	-.01418	.00006	.01105	

ANÁLISE DE DADOS EM GRH

Diagnósticos

- Quando instruímos o SPSS para produzir os diagnósticos, é criado um conjunto variáveis
 - Uma variável com os 'Resíduos Padronizados' da variável dependente (**ZRE_1**) para cada observação
 - Uma variável que mede a distância de Cook associada a cada observação (**COO_1**)
 - Uma variável que mede influência relativa de cada observação no ajuste do modelo (**LEV_1**).
 - Por cada variável independente é criada uma variável com os DFBETA Padronizado, mede a influência de uma dada observação na estimação dos parâmetros.

	evaluation_2	ZRE_1	COO_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1	SDB4_1
1	55.17	-1.13895	.00031	.00075	-.02008	.01582	-.01082	.02414	
2	51.75	-.73316	.00009	.00043	-.00244	.01050	-.00751	-.00841	
3	54.79	.08094	.00000	.00032	.00054	-.00115	.00082	.00032	
4	58.30	-.10802	.00000	.00110	-.00361	.00153	.00227	.00237	
5	49.89	-1.61943	.00061	.00073	.00170	-.02284	.03244	-.01683	
6	52.74	.26865	.00001	.00061	.00066	-.00379	.00543	.00045	
7	47.60	-.51252	.00005	.00059	.00244	-.00757	-.00507	.00848	
8	52.65	-1.39629	.00044	.00069	-.00962	-.02039	.01471	.02727	
9	48.48	-.09011	.00000	.00036	-.00012	-.00130	.00092	.00063	
10	52.40	-.09098	.00000	.00061	-.00032	.00128	-.00183	.00008	
11	47.21	-.93018	.00018	.00064	-.02087	.01351	.01905	-.00301	
12	48.39	.34721	.00004	.00096	.00550	-.00511	-.00699	.00636	
13	50.19	1.06687	.00039	.00117	.01455	-.01579	-.02136	.02492	
14	40.86	1.27964	.00034	.00063	-.02269	.01872	.02621	.00163	
15	45.36	98336	.00013	.00033	.00845	-.01418	.00006	.01105	

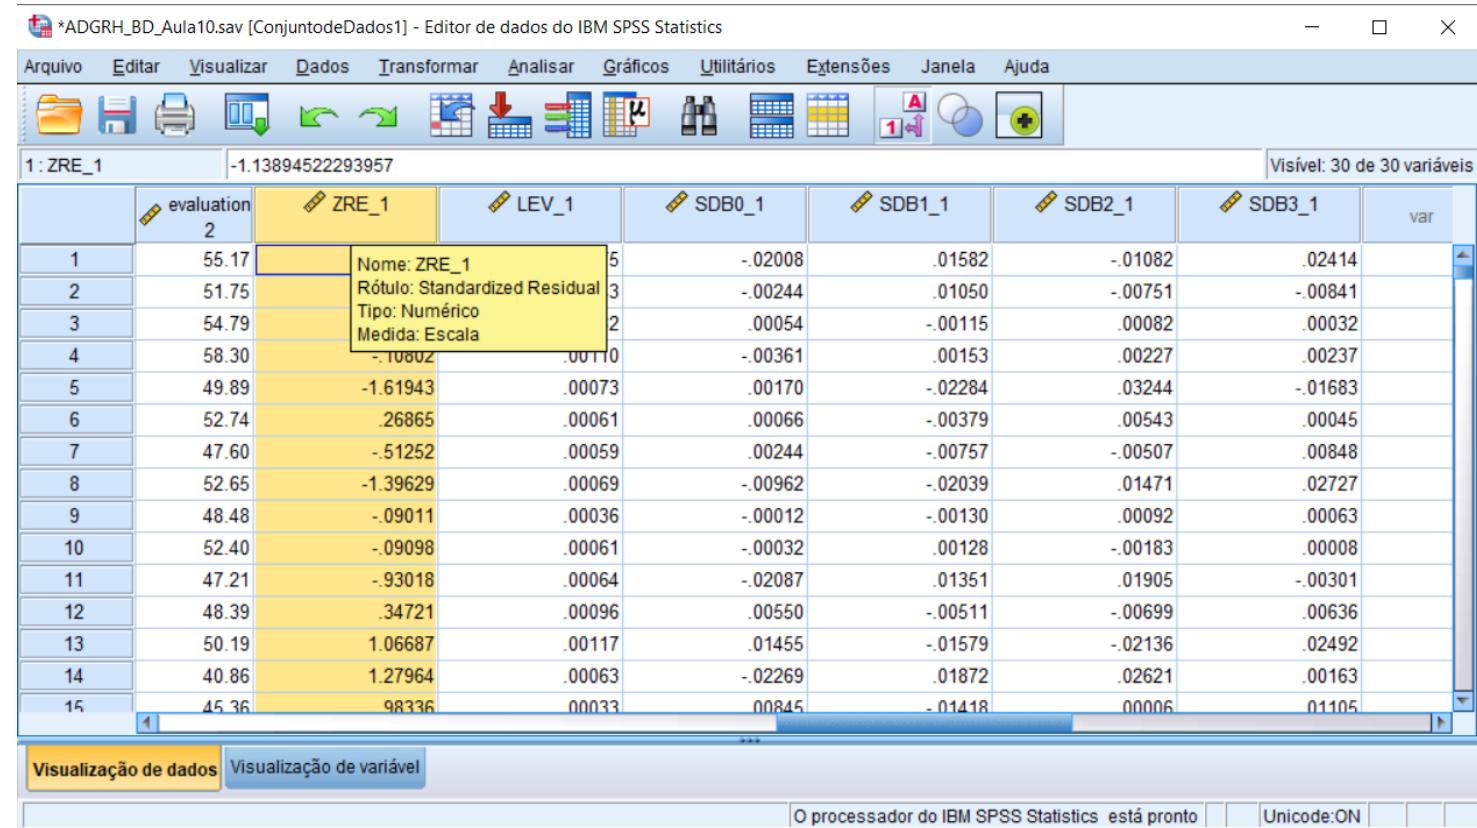
ANÁLISE DE DADOS EM GRH

Validação do Modelo de Regressão Linear

2. Avaliação do Pressuposto II: Normalidade da Distribuição dos Erros

Normalidade da Distribuição dos Erros

- Para avaliarmos se os erros seguem uma distribuição normal, vamos usar a variável com os ‘Resíduos Padronizados’ da VD (ZRE_1) que acabamos de criar.
- Vamos então criar usar um gráfico Q-Q para representar a distribuição dos resíduos padronizados

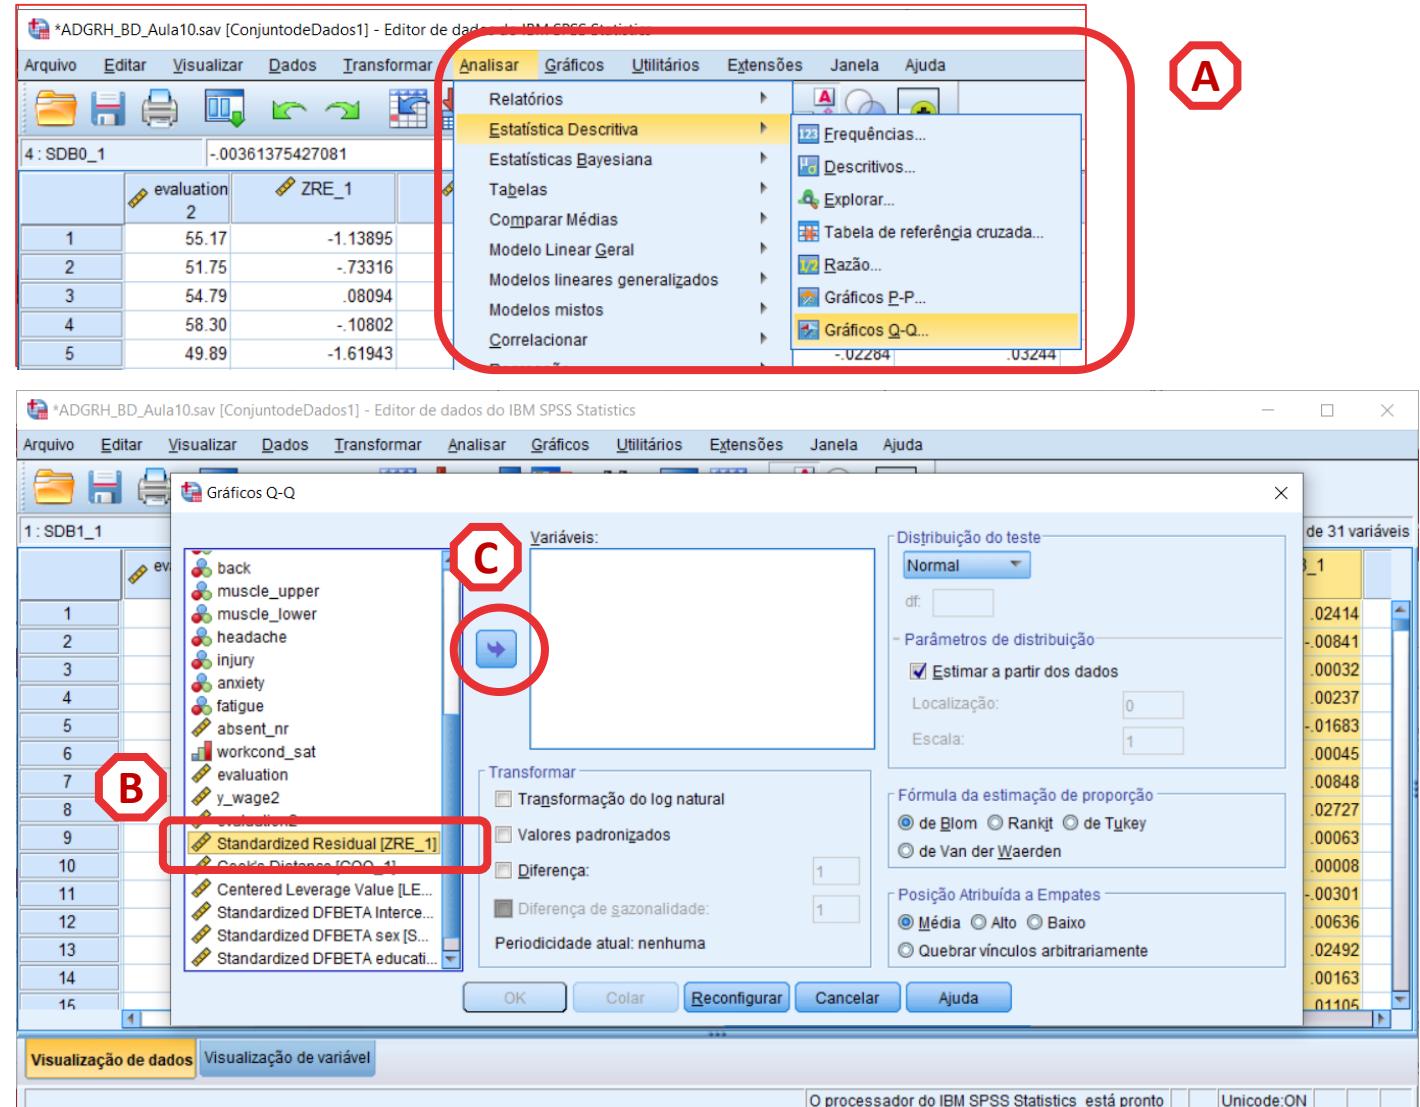


	evaluation	ZRE_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1	var
1	55.17	Nome: ZRE_1 Rótulo: Standardized Residual Tipo: Numérico Medida: Escala	5	-.02008	.01582	-.01082	.02414	
2	51.75		3	-.00244	.01050	-.00751	-.00841	
3	54.79		2	.00054	-.00115	.00082	.00032	
4	58.30		10	-.00361	.00153	.00227	.00237	
5	49.89	-1.61943	.00073	.00170	-.02284	.03244	-.01683	
6	52.74	.26865	.00061	.00066	-.00379	.00543	.00045	
7	47.60	-.51252	.00059	.00244	-.00757	-.00507	.00848	
8	52.65	-1.39629	.00069	-.00962	-.02039	.01471	.02727	
9	48.48	-.09011	.00036	-.00012	-.00130	.00092	.00063	
10	52.40	-.09098	.00061	-.00032	.00128	-.00183	.00008	
11	47.21	-.93018	.00064	-.02087	.01351	.01905	-.00301	
12	48.39	.34721	.00096	.00550	-.00511	-.00699	.00636	
13	50.19	1.06687	.00117	.01455	-.01579	-.02136	.02492	
14	40.86	1.27964	.00063	-.02269	.01872	.02621	.00163	
15	45.36	98336	.00033	.00845	-.01418	00006	01105	

Normalidade da Distribuição dos Erros

- Selecionar ‘Analizar’ / ‘Estatística Descritiva’ / ‘Gráficos Q-Q’
- Selecionar a variável ‘ZRE_1’
- Colocar na caixa ‘Variáveis’
- Selecionar ‘OK’

A



A

Normalidade da Distribuição dos Erros

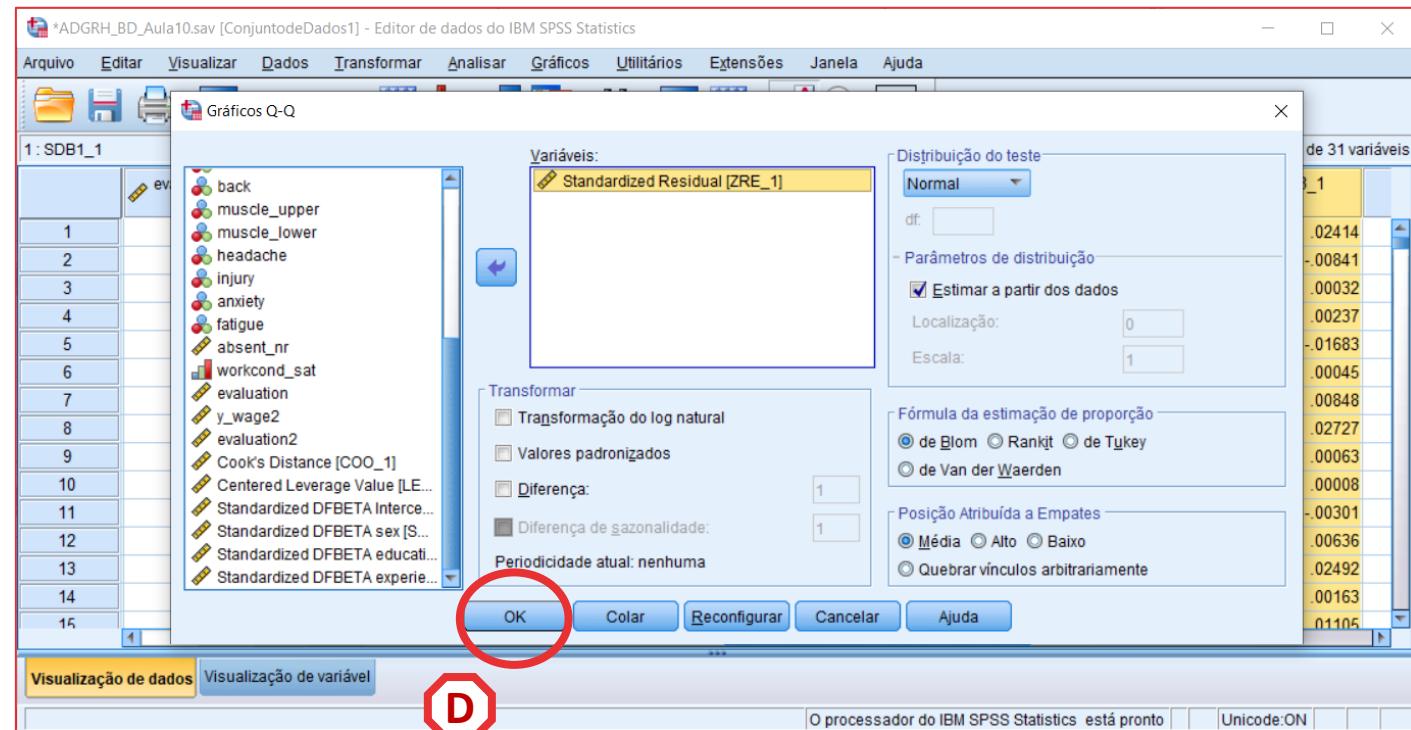
- Selecionar ‘Analizar’ / ‘Estatística Descritiva’ / ‘Gráficos Q-Q’
- Selecionar a variável ‘ZRE_1’
- Colocar na caixa ‘Variáveis’
- Selecionar ‘OK’

A

B

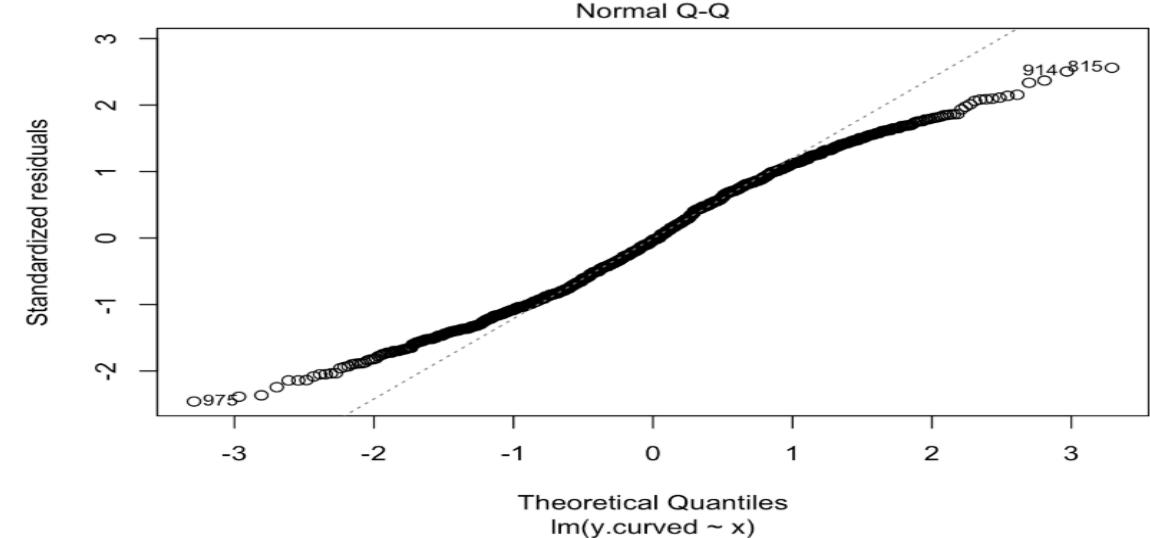
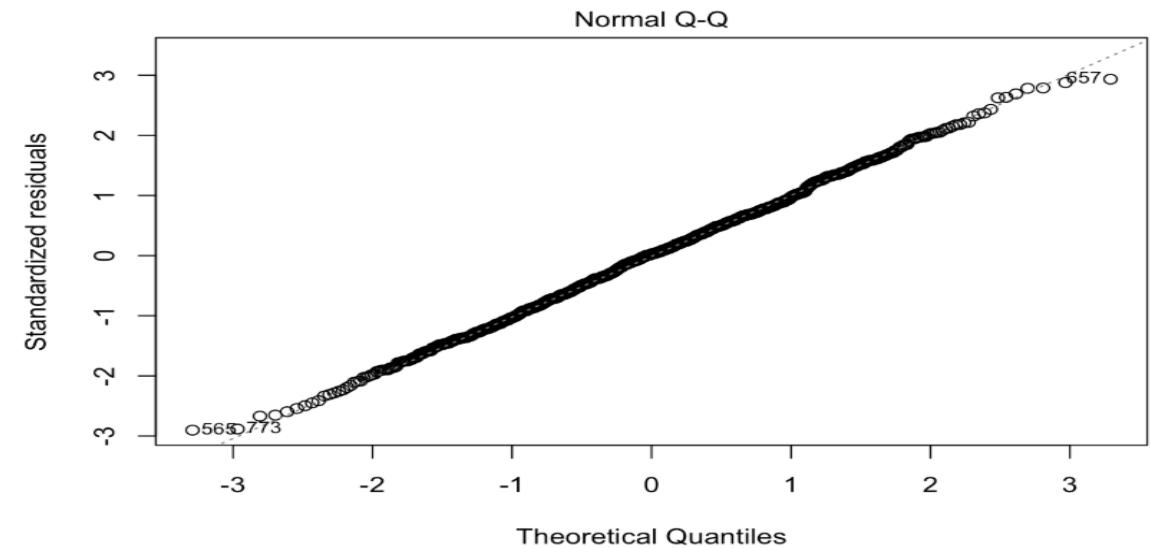
C

D



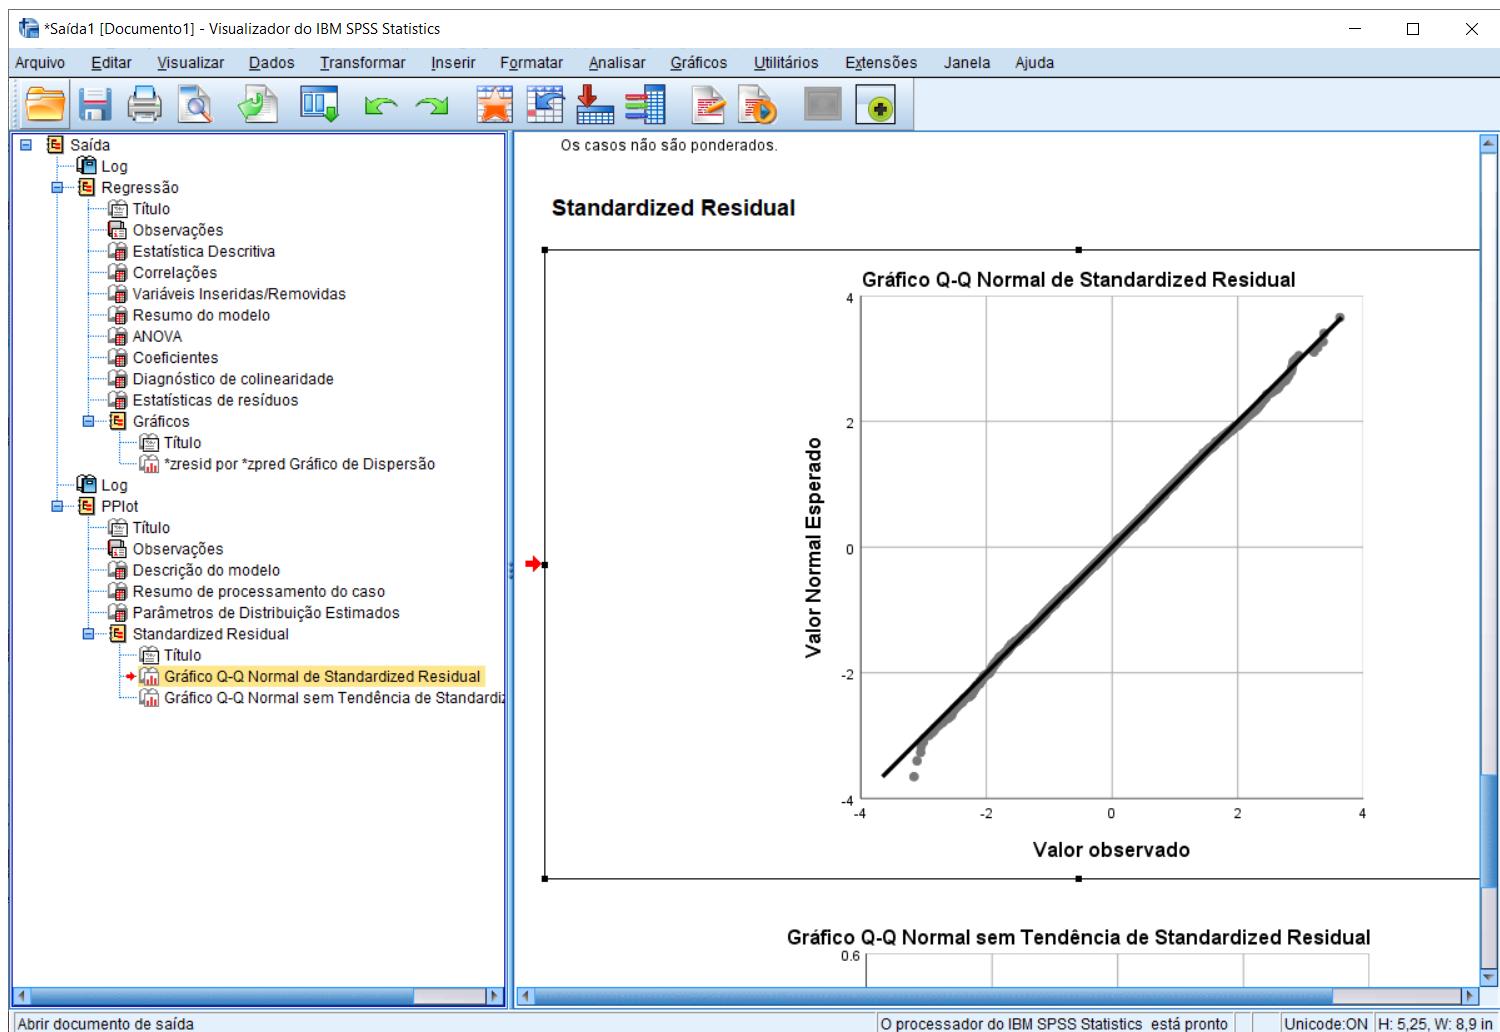
Normalidade da Distribuição dos Erros

- Linha diagonal reflecte uma distribuição normal
- Os resíduos sobrepõe-se quase totalmente com a linha de diagonal
- Os resíduos parecem estar normalmente distribuídos
- Neste, caso os as caudas da distribuição dos resíduos afasta-se da diagonal, o que sugere que a distribuição dos erros pode não ser normal



Normalidade da Distribuição dos Erros

- O gráfico é publicado no 'Visualizador de Resultados'
- Neste caso podemos concluir que os erros seguem uma distribuição normal!



Validação do Modelo de Regressão Linear

3. Avaliação do Pressuposto III: Média Condicional Zero dos Erros

Média Condicional Zero dos Erros

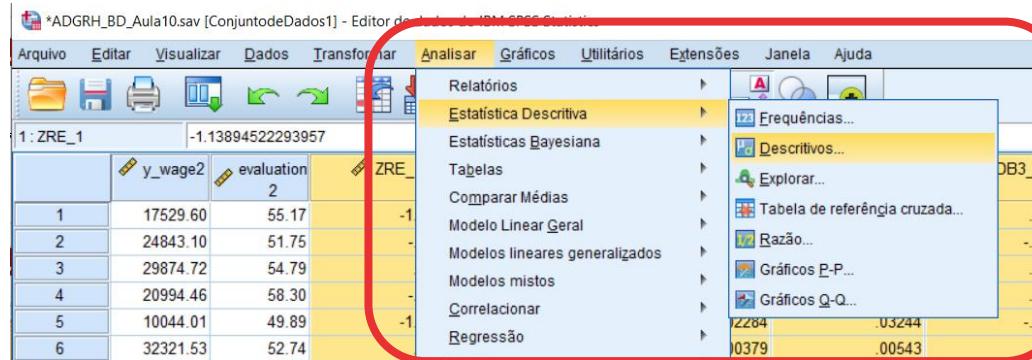
- Para avaliarmos se o termo de erro aleatório tem valor esperado igual a zero, vamos usar a variável com os ‘Resíduos Padronizados’ da VD (ZRE_1) que acabamos de criar.
- Mas neste caso, vamos olhar para as estatísticas descritivas desta variável.

	evaluation 2	ZRE_1	LEV_1	SDB0_1	SDB1_1	SDB2_1	SDB3_1	var
1	55.17	Nome: ZRE_1 Rótulo: Standardized Residual Tipo: Numérico Medida: Escala	5	-.02008	.01582	-.01082	.02414	
2	51.75		3	-.00244	.01050	-.00751	-.00841	
3	54.79		2	.00054	-.00115	.00082	.00032	
4	58.30		10	-.00361	.00153	.00227	.00237	
5	49.89	-1.61943	.00073	.00170	-.02284	.03244	-.01683	
6	52.74	.26865	.00061	.00066	-.00379	.00543	.00045	
7	47.60	-.51252	.00059	.00244	-.00757	-.00507	.00848	
8	52.65	-1.39629	.00069	-.00962	-.02039	.01471	.02727	
9	48.48	-.09011	.00036	-.00012	-.00130	.00092	.00063	
10	52.40	-.09098	.00061	-.00032	.00128	-.00183	.00008	
11	47.21	-.93018	.00064	-.02087	.01351	.01905	-.00301	
12	48.39	.34721	.00096	.00550	-.00511	-.00699	.00636	
13	50.19	1.06687	.00117	.01455	-.01579	-.02136	.02492	
14	40.86	1.27964	.00063	-.02269	.01872	.02621	.00163	
15	45.36	98336	.00033	.00845	-.01418	00006	01105	

Média Condisional Zero dos Erros

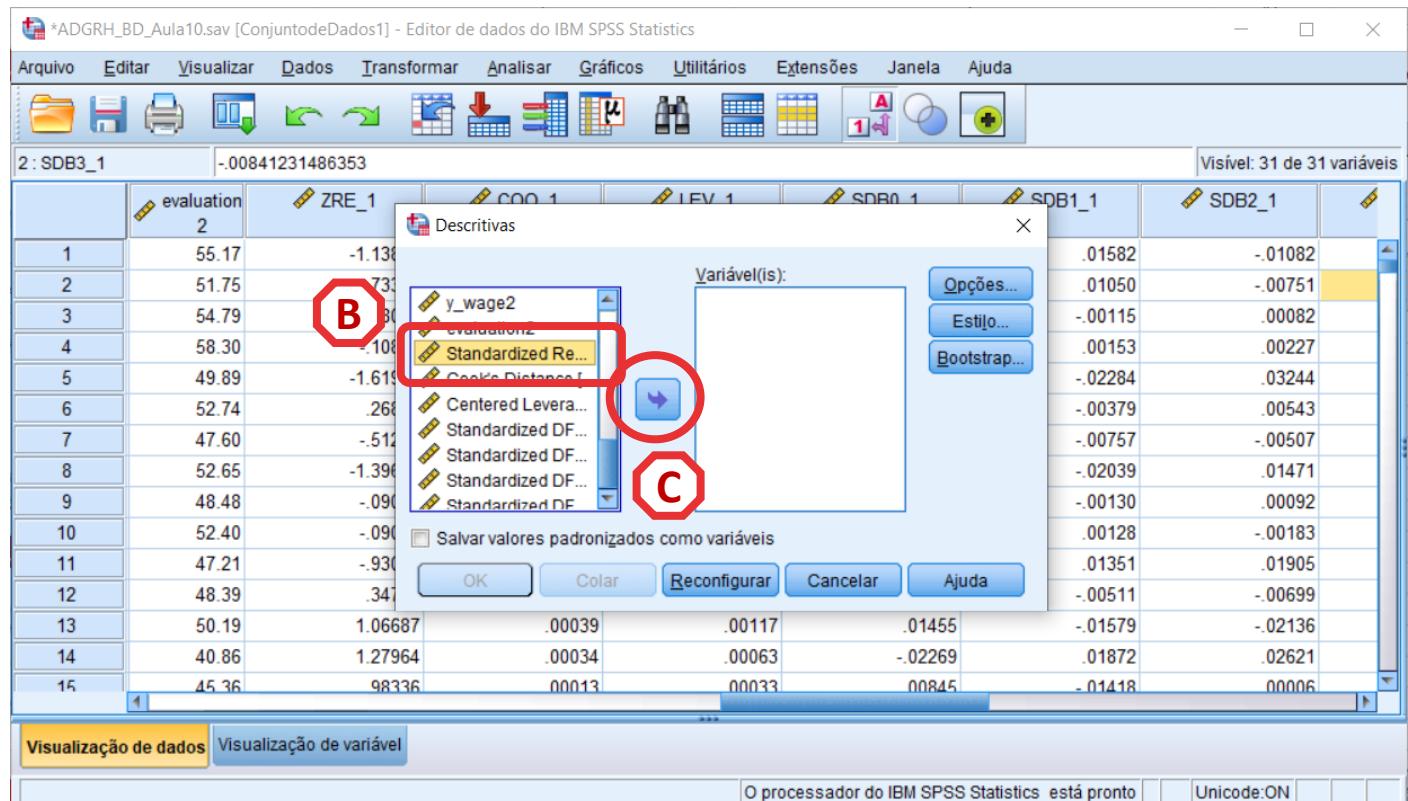
- Selecionar 'Analizar' / 'Estatística Descritiva' / 'Descritivos'

A



- Selecionar a variável 'ZRE_1'

B



- Colocar na caixa 'Variável(is)'

C

- Selecionar 'OK'

D

Média Condisional Zero dos Erros

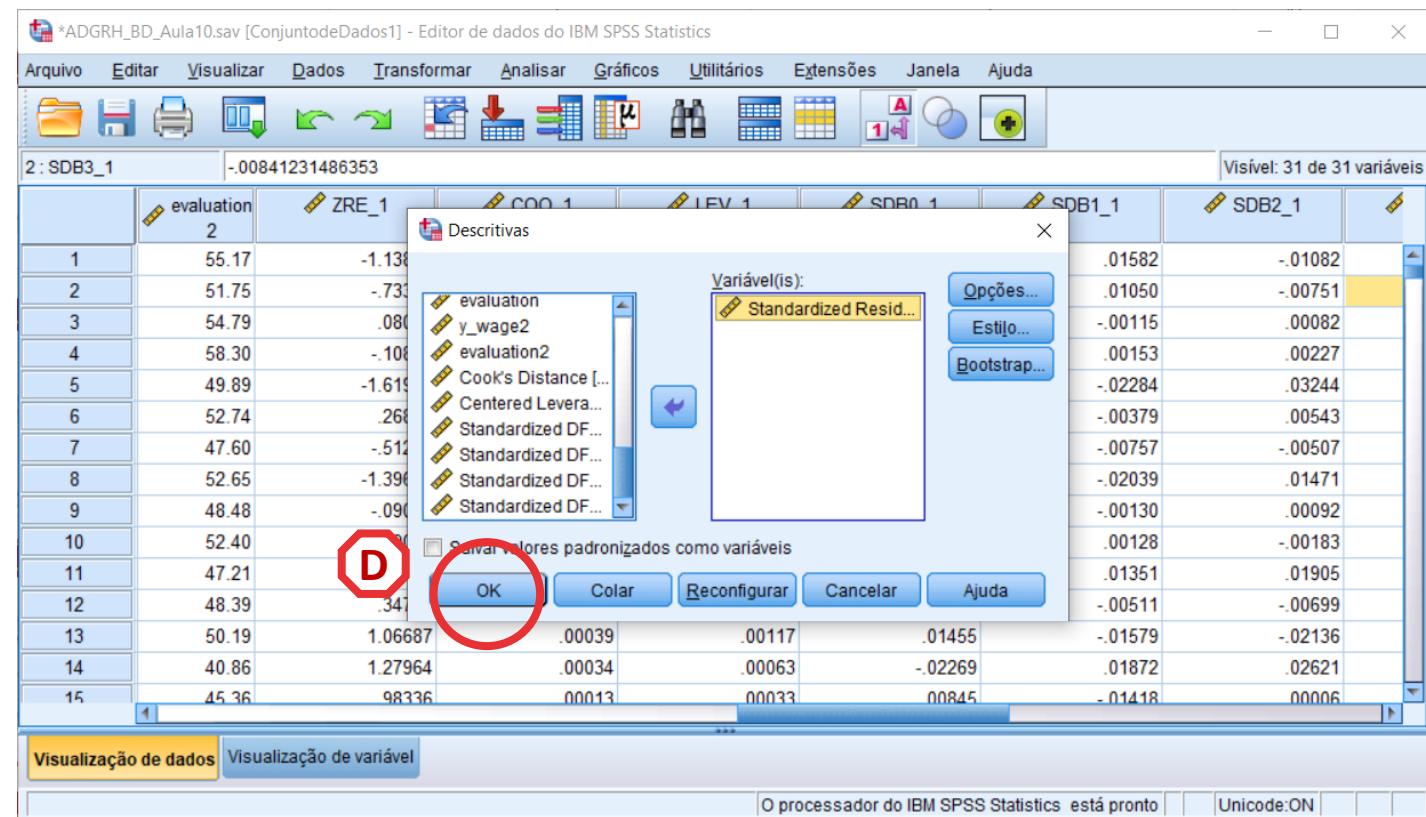
- Selecionar ‘Analizar’ / ‘Estatística Descritiva’ / ‘Descritivos’
- Selecionar a variável ‘ZRE_1’
- Colocar na caixa ‘Variável(is)’
- Selecionar ‘OK’

A

B

C

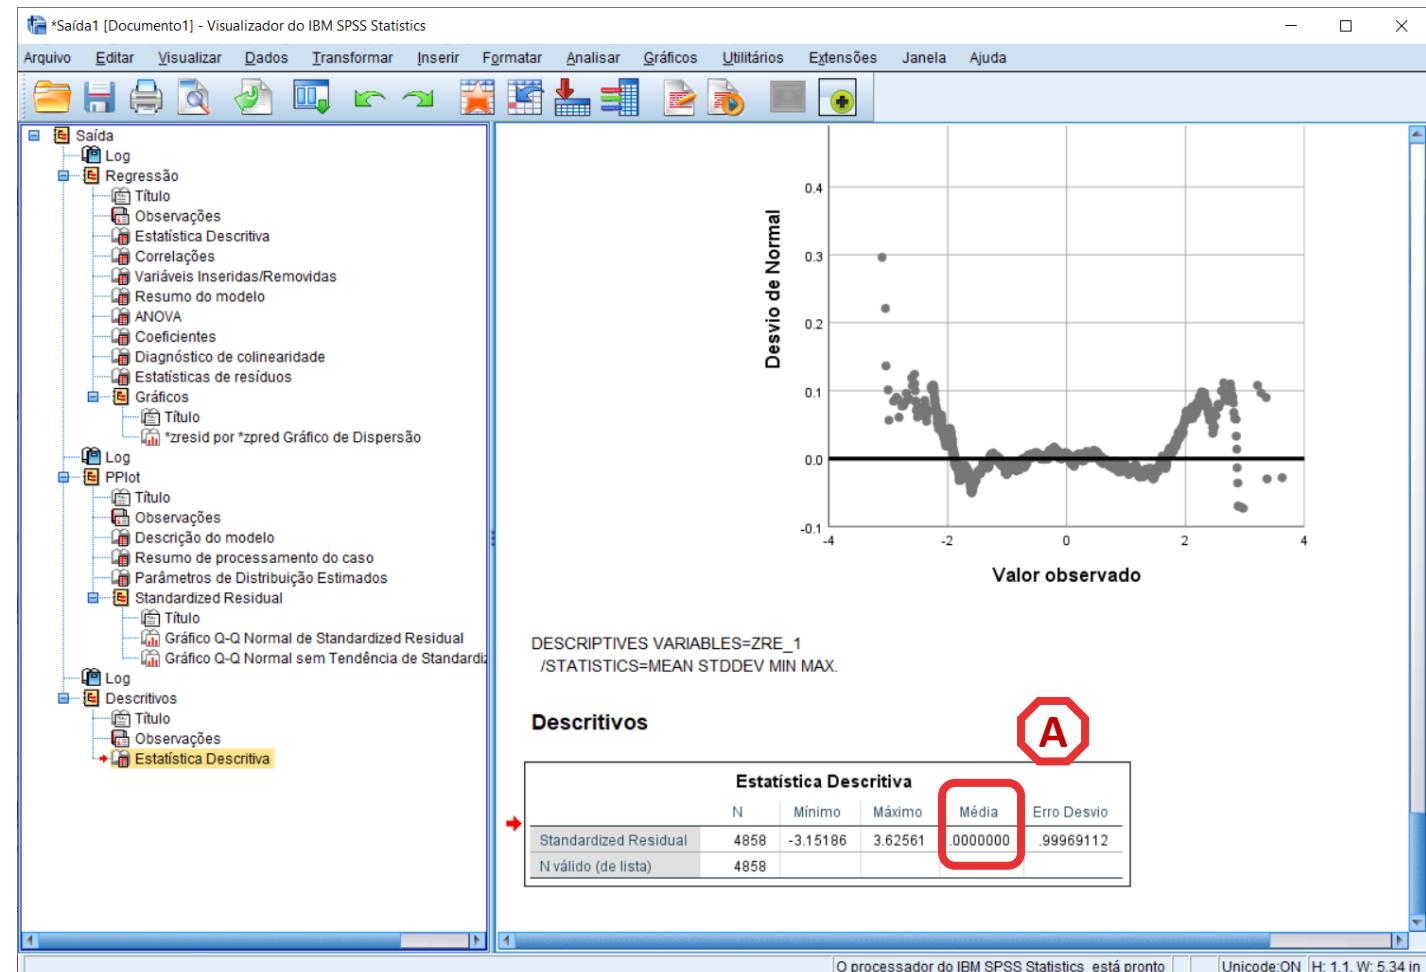
D



Média Condisional Zero dos Erros

- O gráfico é publicado no ‘Visualizador de Resultados’
- Os ‘Resíduos Padronizados’ da VD (ZRE_1) tem uma média muito próximo de 0,
- Neste caso podemos concluir que se cumpre o pressuposto da Média Condisional Zero dos Erros.

A



ANÁLISE DE DADOS EM GRH

Validação do Modelo de Regressão Linear

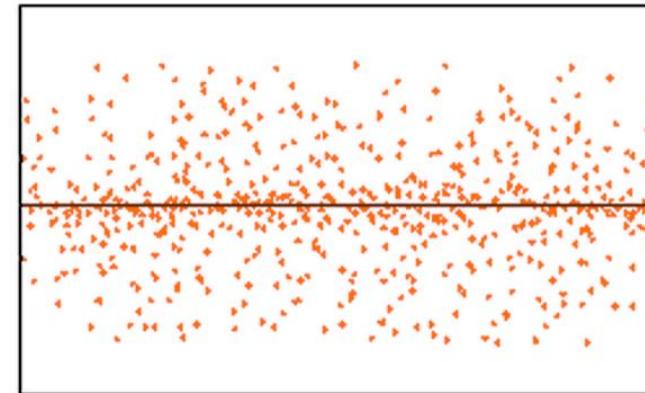
4. Avaliação do Pressuposto IV: Homocedasticidade

ANÁLISE DE DADOS EM GRH

Homocedasticidade (ou Igual Variância)

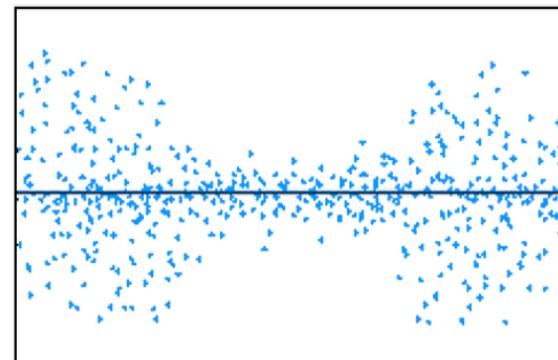
- A distribuição dos resíduos apresenta uma variância constante ao longo dos valores previstos da variável dependente. Não há indicação de variação não-constante.

Homoscedasticity



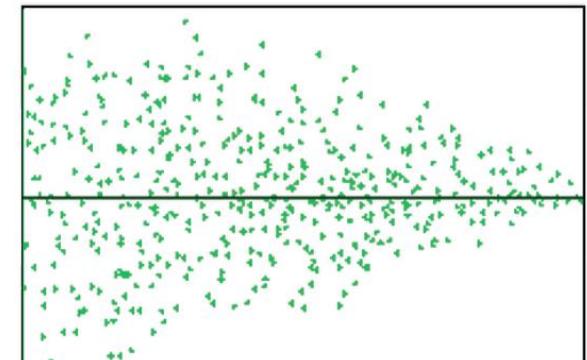
Random Cloud (No Discernible Pattern)

Heteroscedasticity



Bow Tie Shape (Pattern)

Heteroscedasticity



Fan Shape (Pattern)

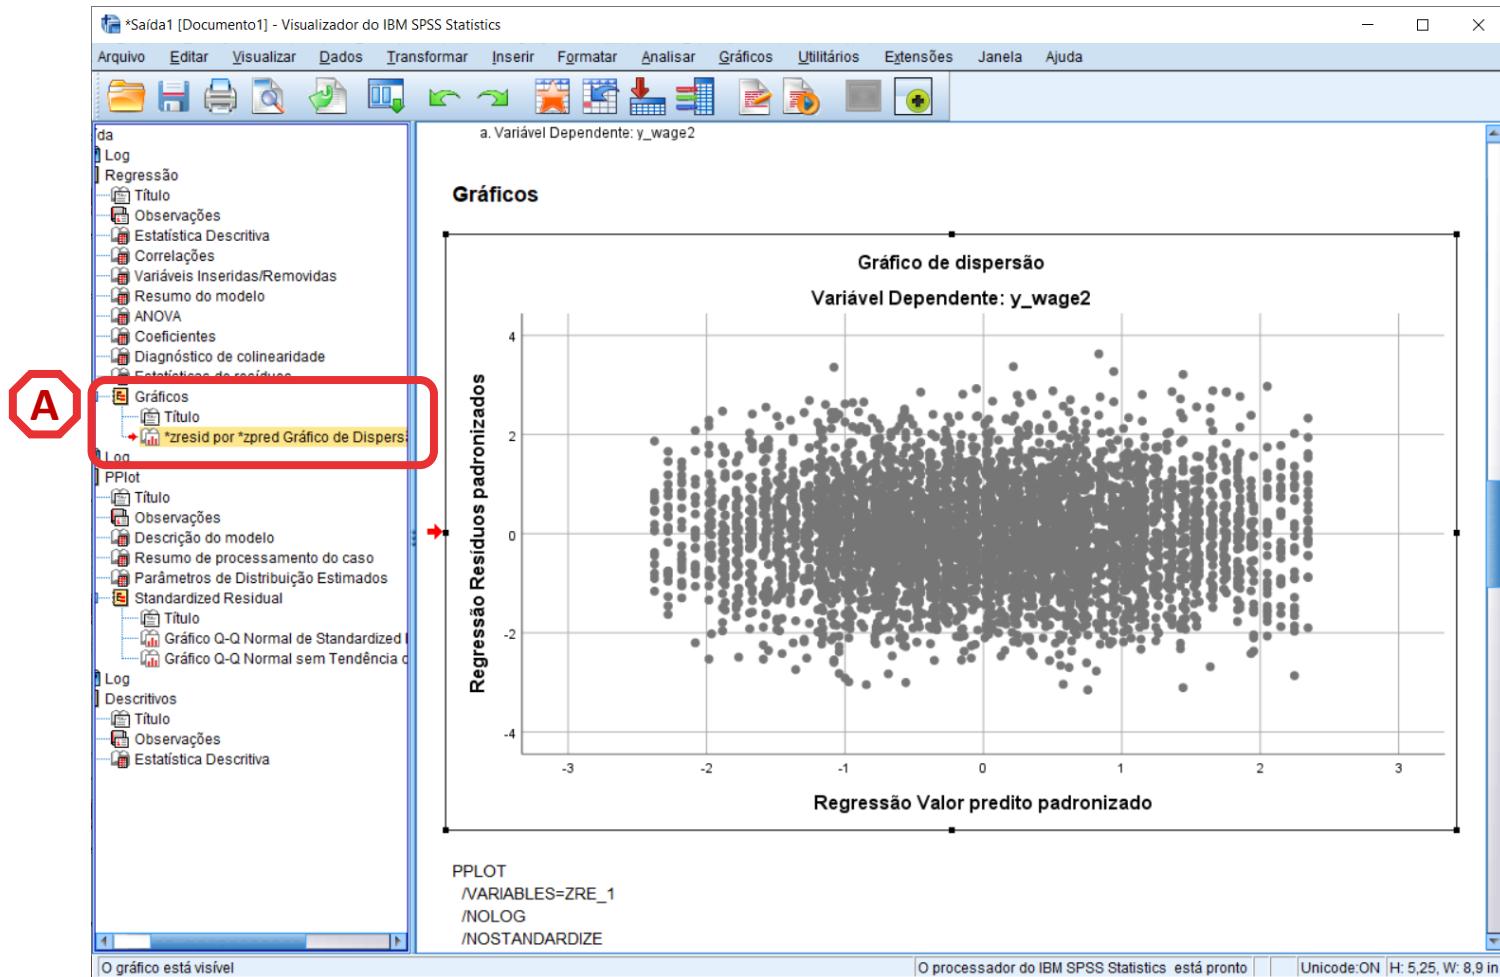
ou seja, a variação não é constante.

ANÁLISE DE DADOS EM GRH

Homocedasticidade

- Para avaliar se se cumpre este pressuposto, temos de olhar para o Gráfico de Dispersão que compara a distribuição dos 'Resíduos Padronizados' com os 'Valores Preditos Padronizados' - que o SPSS produz automaticamente.
- Neste caso, a representação da distribuição parece sugerir que a variação dos resíduos é relativamente constante.
- Ou seja, cumpre-se o pressuposto da Homocedasticidade

A



ANÁLISE DE DADOS EM GRH

Validação do Modelo de Regressão Linear

5. Avaliação do Pressuposto V: Independência dos Erros

Independência dos Erros

- Para avaliar se se cumpre este pressuposto, temos de olhar para o resultado do teste Durbin-Watson - que pedimos ao SPSS para produzir.

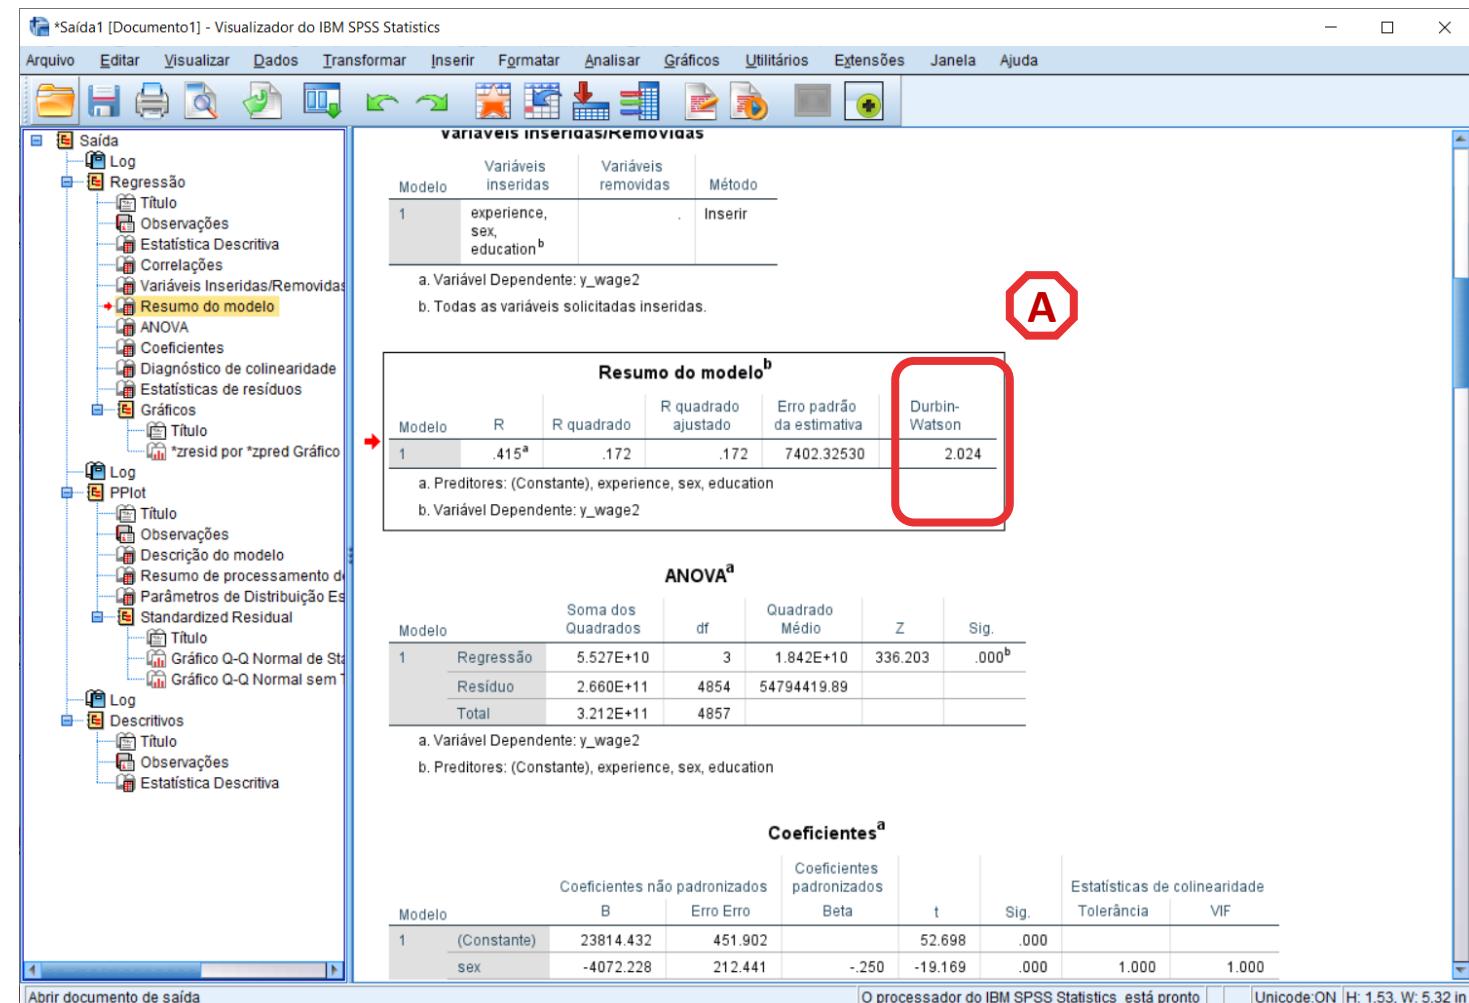
- Interpretação:

= 2 → Erros são independentes

> 2 / < 2 → Erros não são independentes

- Neste caso os erros são independentes

A



ANÁLISE DE DADOS EM GRH

Validação do Modelo de Regressão Linear

6. Avaliação do Pressuposto VI: Ausência de Multicolinearidade Perfeita

ANÁLISE DE DADOS EM GRH

Ausência de Multicolinearidade Perfeita

- Quando há fortes relações lineares entre os preditores numa regressão, a precisão dos coeficientes de regressão diminui em comparação com o que teria sido se os preditores não se correlacionassem entre si
- Um valor de VIF > 3 sugere a existência de colinearidade no modelo
- Um valor de VIF > 10 sugere a existência de colinearidade séria
- Deve repensar-se as variáveis a incluir no modelo

ANÁLISE DE DADOS EM GRH

Ausência de Multicolinearidade

- Para testarmos este pressuposto, temos de olhar para a Tabela de Coeficientes - que o SPSS produz automaticamente.
- Interpretação

VIF > 3 -> presença de colinearidade

- Neste caso, não se identifica a presença de colinearidade...
- Portanto, cumpre-se o pressuposto da ausência de Multicolinearidade

*Saída1 [Documento1] - Visualizador do IBM SPSS Statistics

Arquivo Editar Visualizar Dados Transformar Inserir Formatar Analisar Gráficos Utilitários Extensões Janela Ajuda

Total 3.212E+11 4857

a. Variável Dependente: y_wage2
b. Preditores: (Constante), experience, sex, education

Modelo	Coeficientes não padronizados		Coeficientes padronizados		Estatísticas de colinearidade		
	B	Erro	Beta	t	Sig.	Tolerância	VIF
1	(Constante)	23814.432	451.902	52.698	.000		
	sex	-4072.228	212.441	-.250	-19.169	.000	1.000
	education	1388.801	75.323	.241	18.438	.000	.999
	experience	331.517	18.584	.233	17.839	.000	.999

a. Variável Dependente: y_wage2

Modelo	Dimensão	Autovalor	Índice de condição	Proporções de variância			
				(Constante)	sex	education	experience
1	1	3.612	1.000	.00	.01	.01	.01
	2	.211	4.139	.00	.01	.30	.68
	3	.138	5.115	.02	.35	.48	.18
	4	.039	9.654	.98	.63	.21	.13

a. Variável Dependente: y_wage2

	Mínimo	Máximo	Média	Erro Desvio	N
Valor previsto	17390.2930	33316.5391	25405.6559	3373.22893	4858
Erro Valor previsto	-2.376	2.345	.000	1.000	4858
Erro padrão do valor previsto	150.030	280.674	209.876	32.697	4858
Valor previsto ajustado	17370.3906	33336.3047	25405.6766	3373.23731	4858

O processador do IBM SPSS Statistics está pronto | Unicode:ON | H: 2,19, W: 7,74 in

ANÁLISE DE DADOS EM GRH

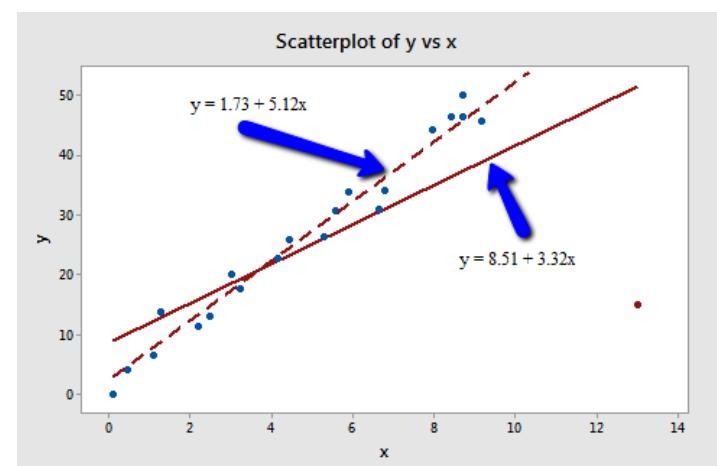
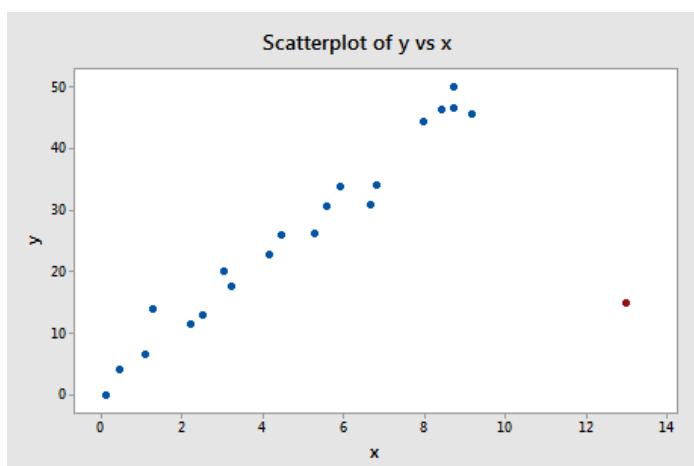
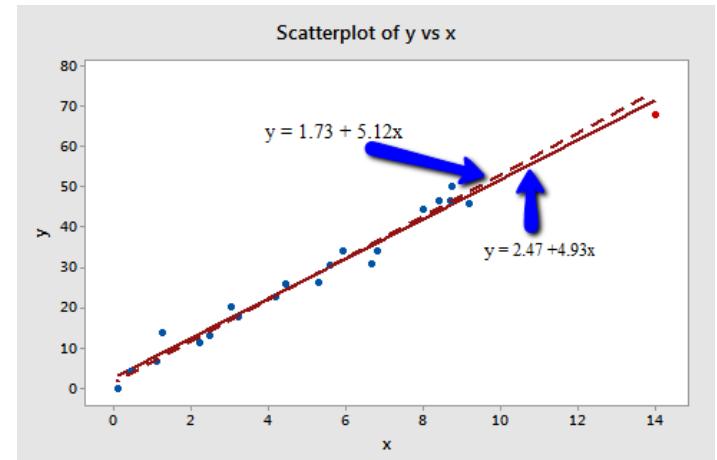
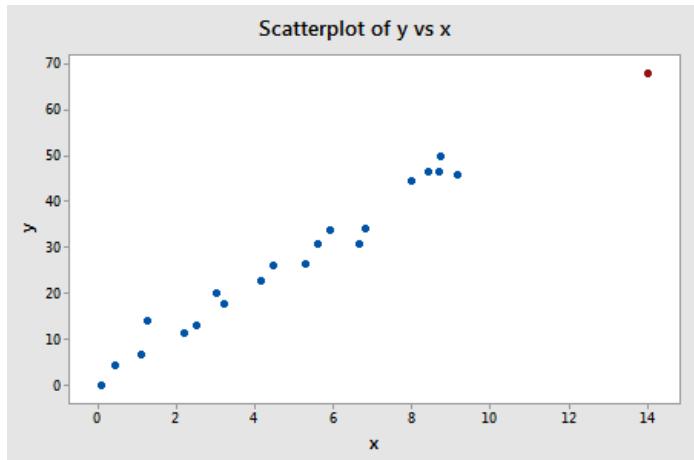
Validação do Modelo de Regressão Linear

7. Avaliação do Pressuposto VII: Ausência de Observações Influentes

ANÁLISE DE DADOS EM GRH

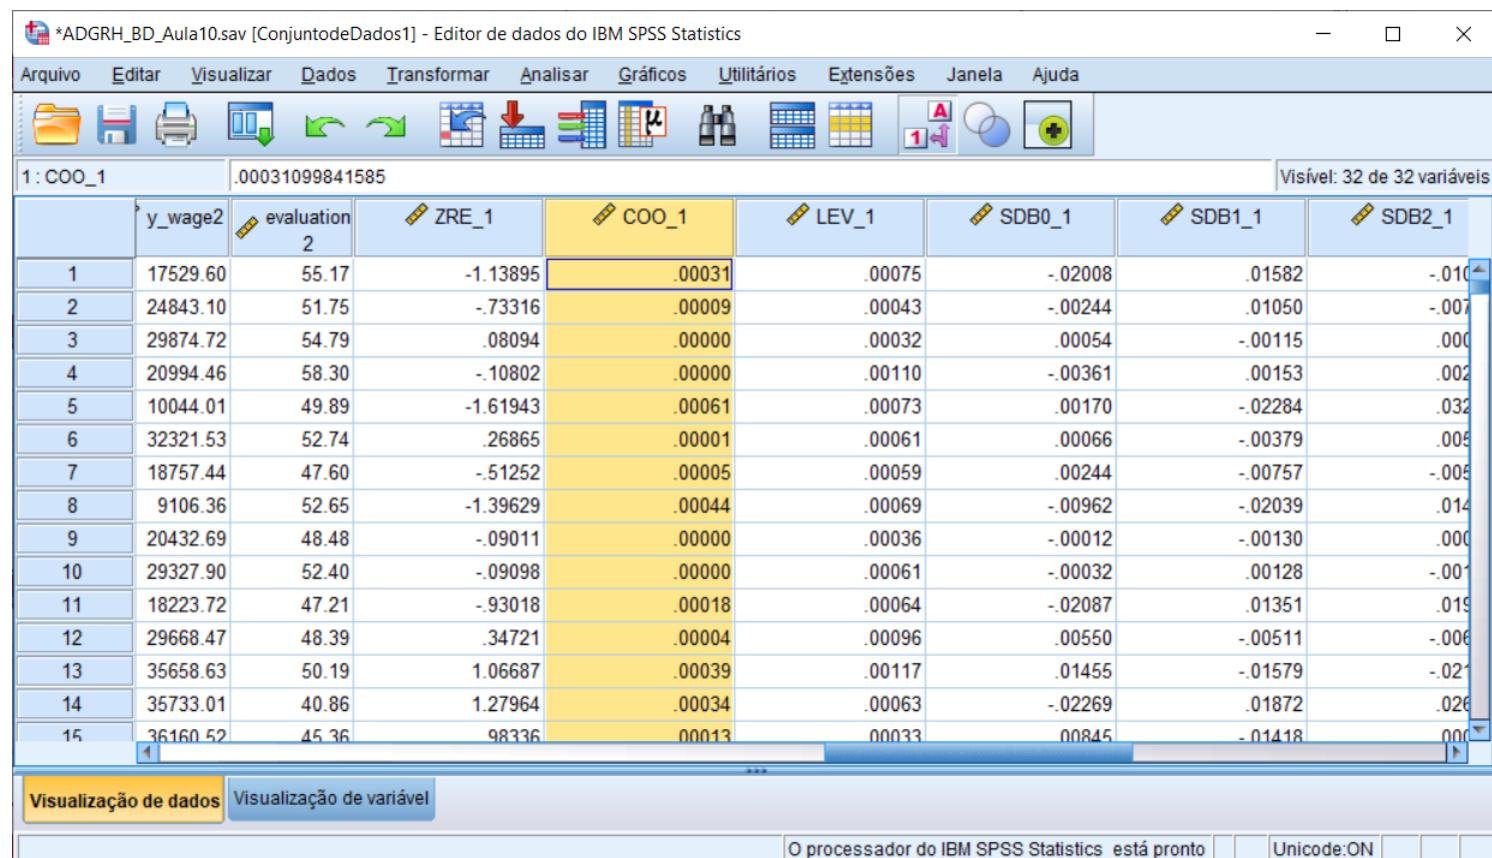
Ausência de Observações Influentes

- A existência de ‘Outliers’ (valores extremos) não é um problema em si.
- Mas torna-se um problema quando os Outlier têm influência sobre os resultados do modelo
- Nos painéis de baixo, o Outlier é uma ‘Observação Influente’



Ausência de Observações Influentes

- Para testarmos a presença de observações influentes vamos usar a variável com os 'Distância de Cook' (COO_1) que acabamos de criar.



	y_wage2	evaluation 2	ZRE_1	COO_1	LEV_1	SDB0_1	SDB1_1	SDB2_1
1	17529.60	55.17	-1.13895	.00031	.00075	-.02008	.01582	-.010
2	24843.10	51.75	-.73316	.00009	.00043	-.00244	.01050	-.007
3	29874.72	54.79	.08094	.00000	.00032	.00054	-.00115	.000
4	20994.46	58.30	-.10802	.00000	.00110	-.00361	.00153	.002
5	10044.01	49.89	-1.61943	.00061	.00073	.00170	-.02284	.032
6	32321.53	52.74	.26865	.00001	.00061	.00066	-.00379	.005
7	18757.44	47.60	-.51252	.00005	.00059	.00244	-.00757	-.005
8	9106.36	52.65	-1.39629	.00044	.00069	-.00962	-.02039	.014
9	20432.69	48.48	-.09011	.00000	.00036	-.00012	-.00130	.000
10	29327.90	52.40	-.09098	.00000	.00061	-.00032	.00128	-.001
11	18223.72	47.21	-.93018	.00018	.00064	-.02087	.01351	.019
12	29668.47	48.39	.34721	.00004	.00096	.00550	-.00511	-.006
13	35658.63	50.19	1.06687	.00039	.00117	.01455	-.01579	-.021
14	35733.01	40.86	1.27964	.00034	.00063	-.02269	.01872	.026
15	36160.52	45.36	98336	.00013	.00033	.00845	-.01418	.000

Ausência de Observações Influentes

- Selecionar ‘Gráficos’ / ‘Construtor de Gráfico’

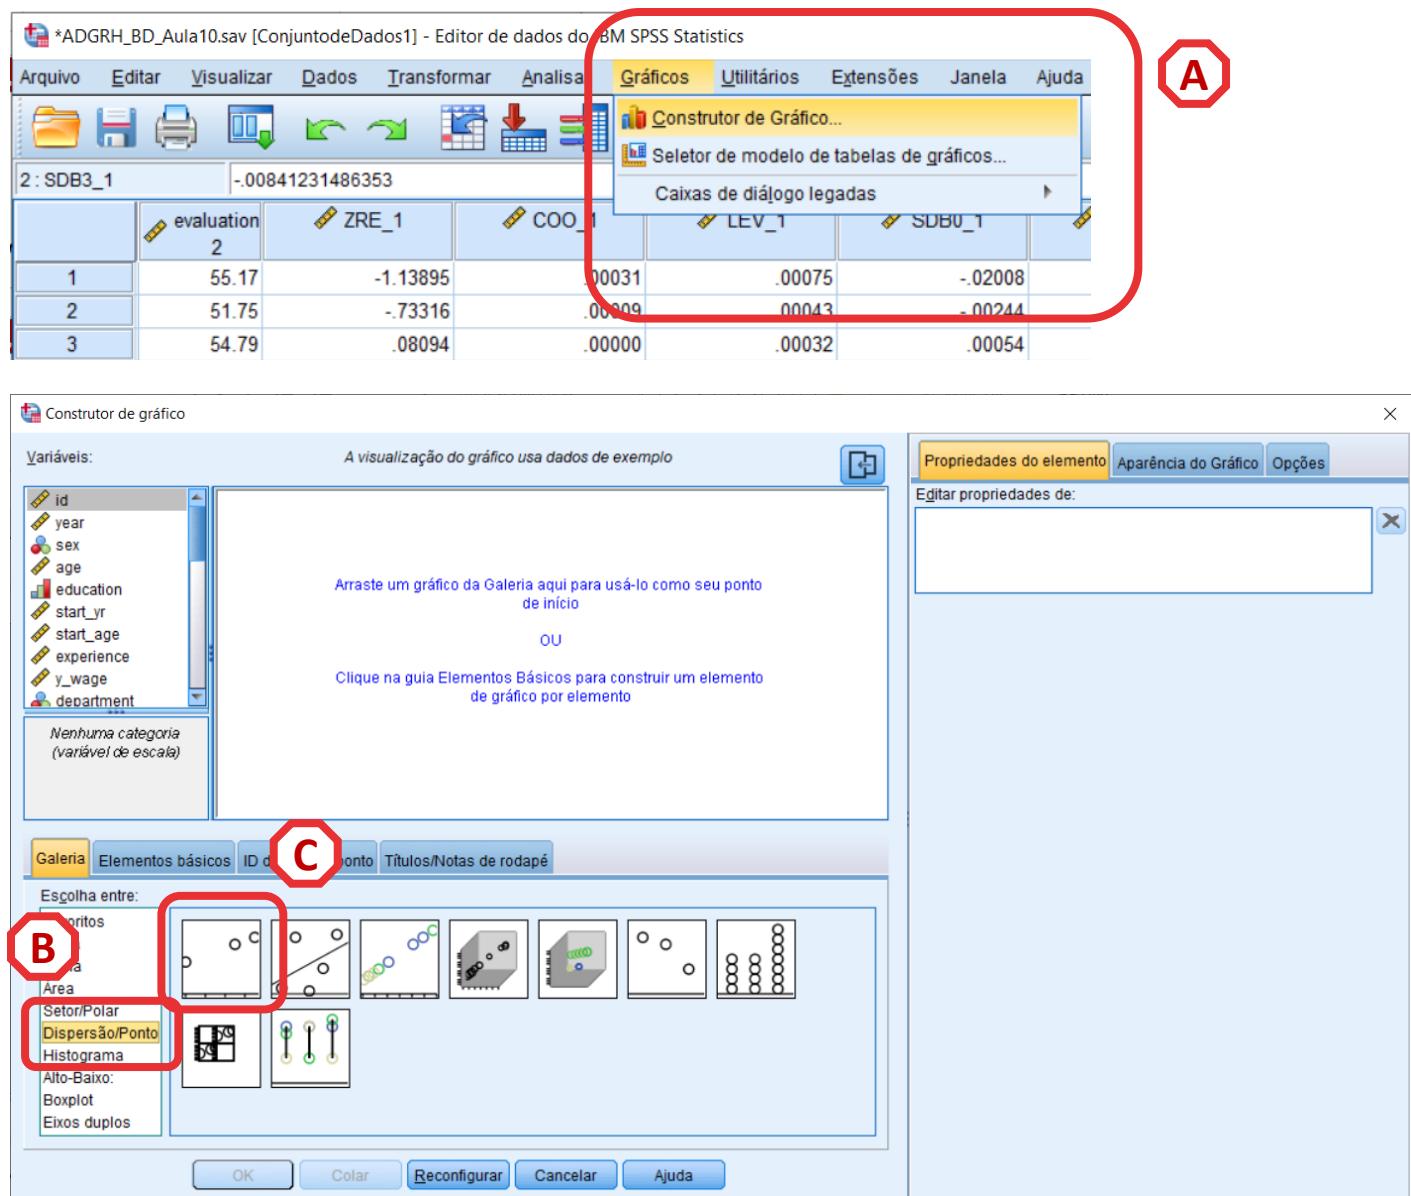
A

- Selecionar ‘DispersãoPontos’

B

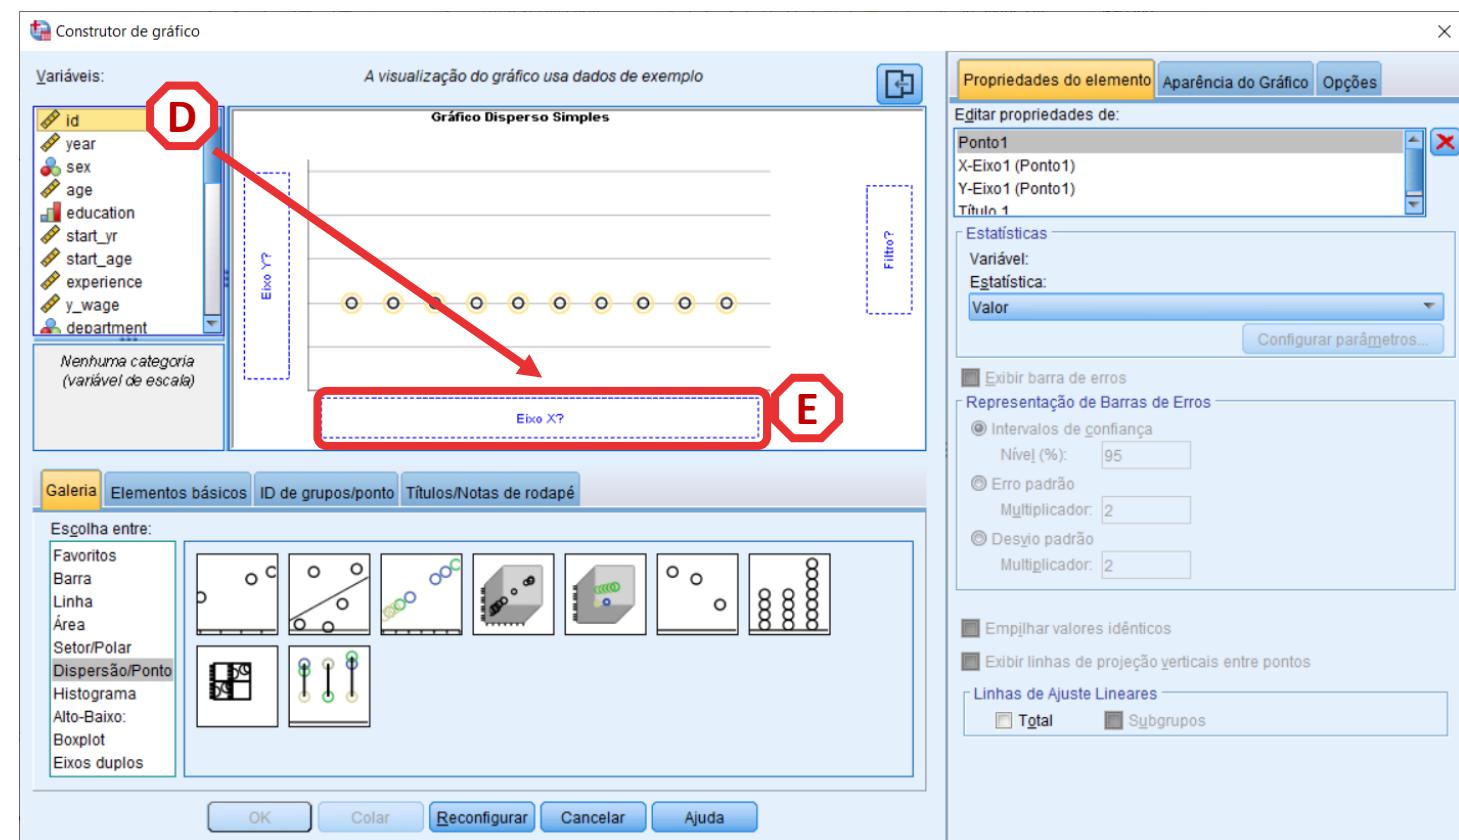
- Selecionar ‘Dispersão (Simples)’

C



Ausência de Observações Influentes

- Selecionar ‘Gráficos’ / ‘Construtor de Gráfico’ A
- Selecionar ‘DispersãoPontos’ B
- Selecionar ‘Dispersão (Simples)’ C
- Selecionar Variável ‘id’ D
- Colocar no eixo ‘x’ E



Ausência de Observações Influentes

- Selecionar ‘Gráficos’ / ‘Construtor de Gráfico’
- Selecionar ‘DispersãoPontos’
- Selecionar ‘Dispersão (Simples)’
- Selecionar Variável ‘id’
- Colocar no eixo ‘x’
- Selecionar Variável ‘Cooks Distance’
- Colocar no eixo ‘x’

(A)

(F)

(B)

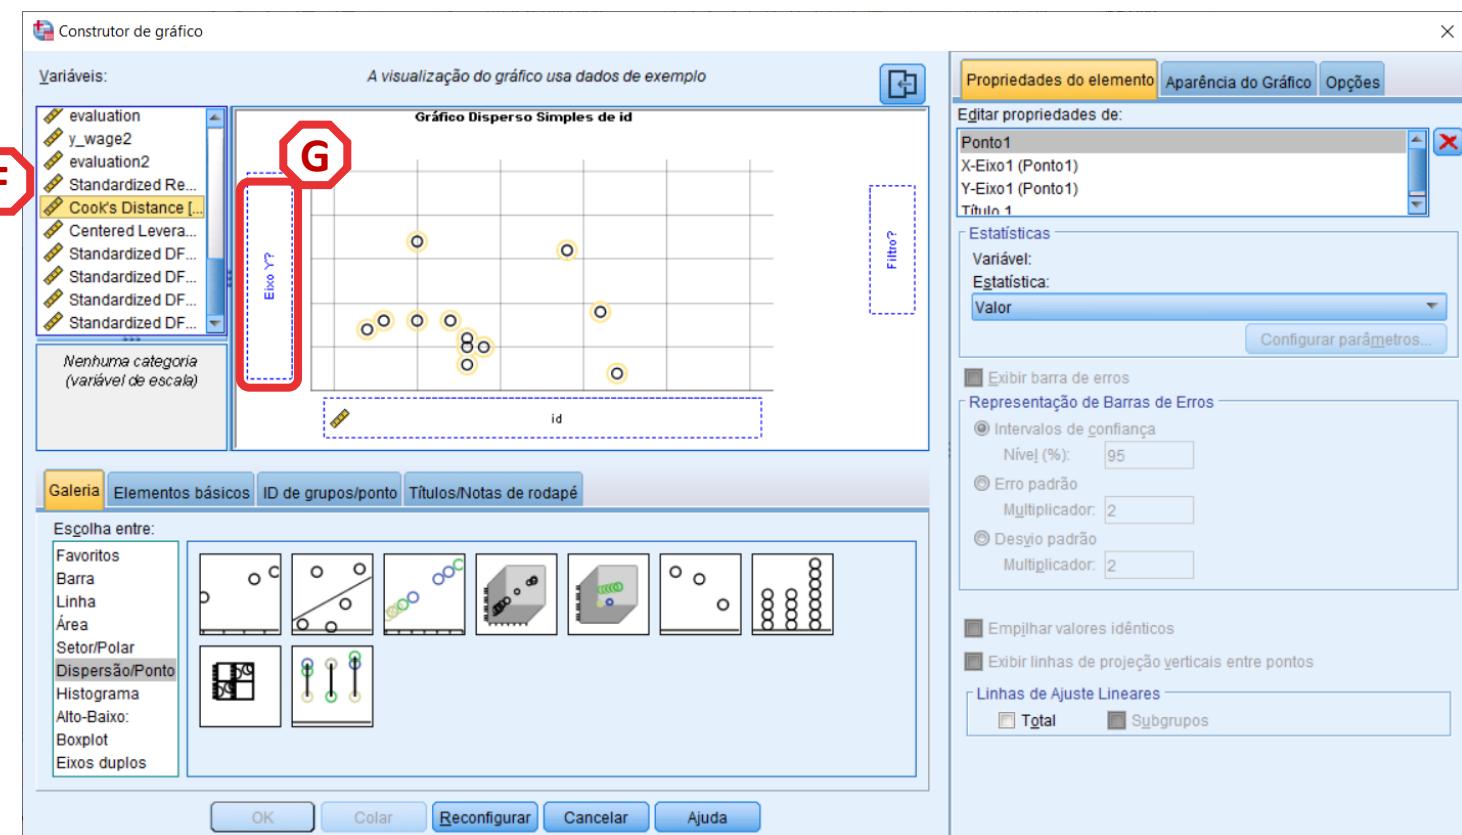
(C)

(D)

(E)

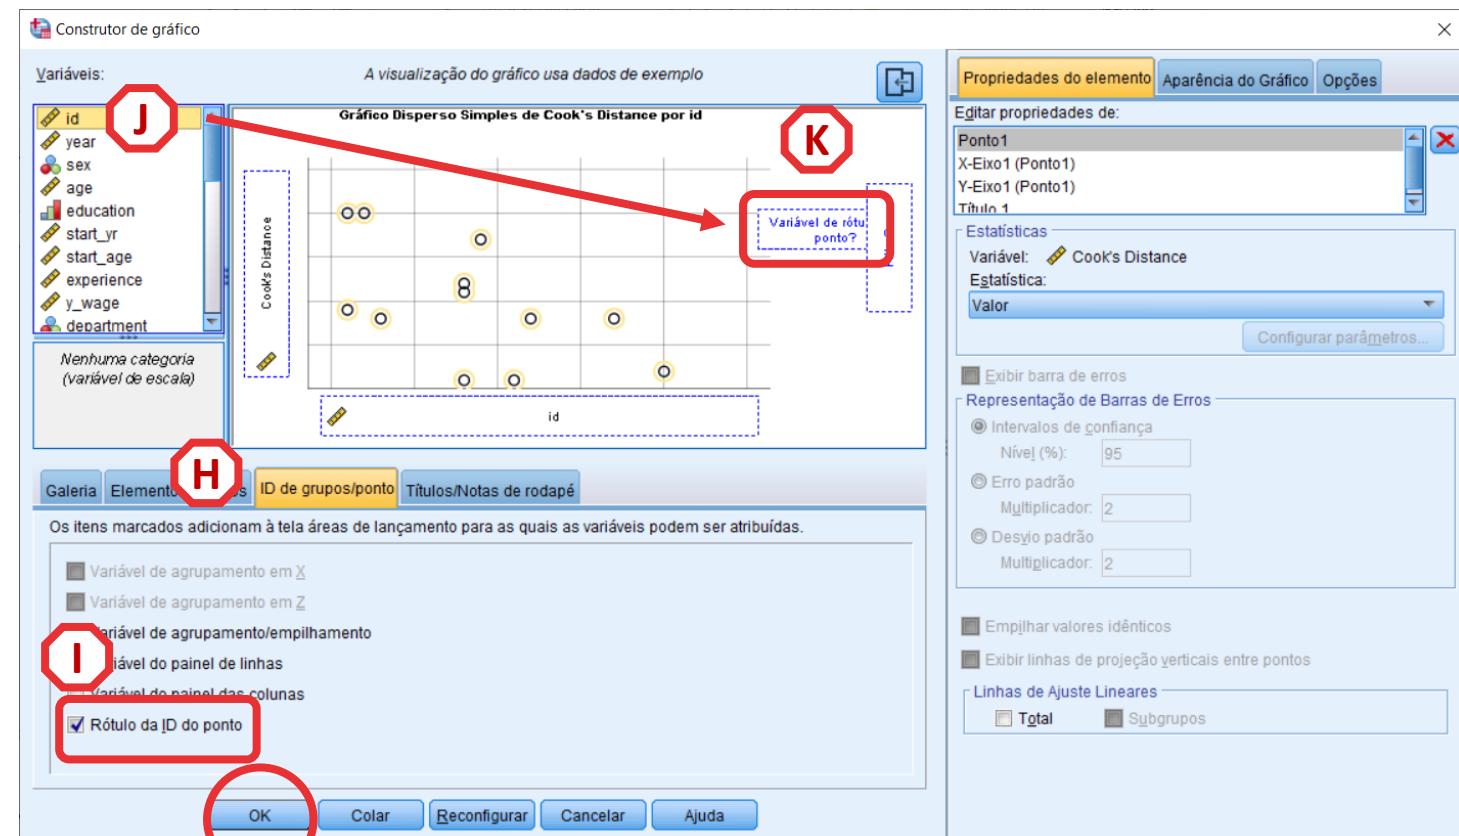
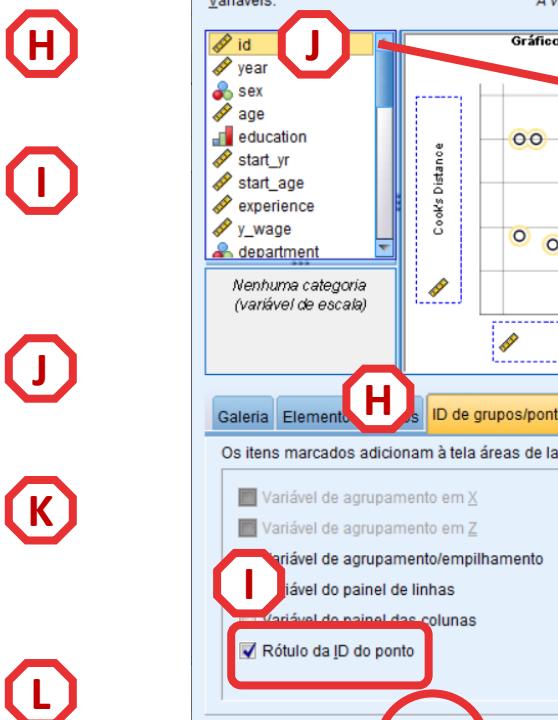
(F)

(G)



Ausência de Observações Influentes

- **Selecionar ‘ID de grupos/ponto’**
 - **Selecionar ‘Rótulo da ID do Ponto’**
 - **Selecionar Variável ‘id’**
 - **Colocar na caixa ‘Variável do rótulo do ponto’**
 - **Selecionar ‘OK’**

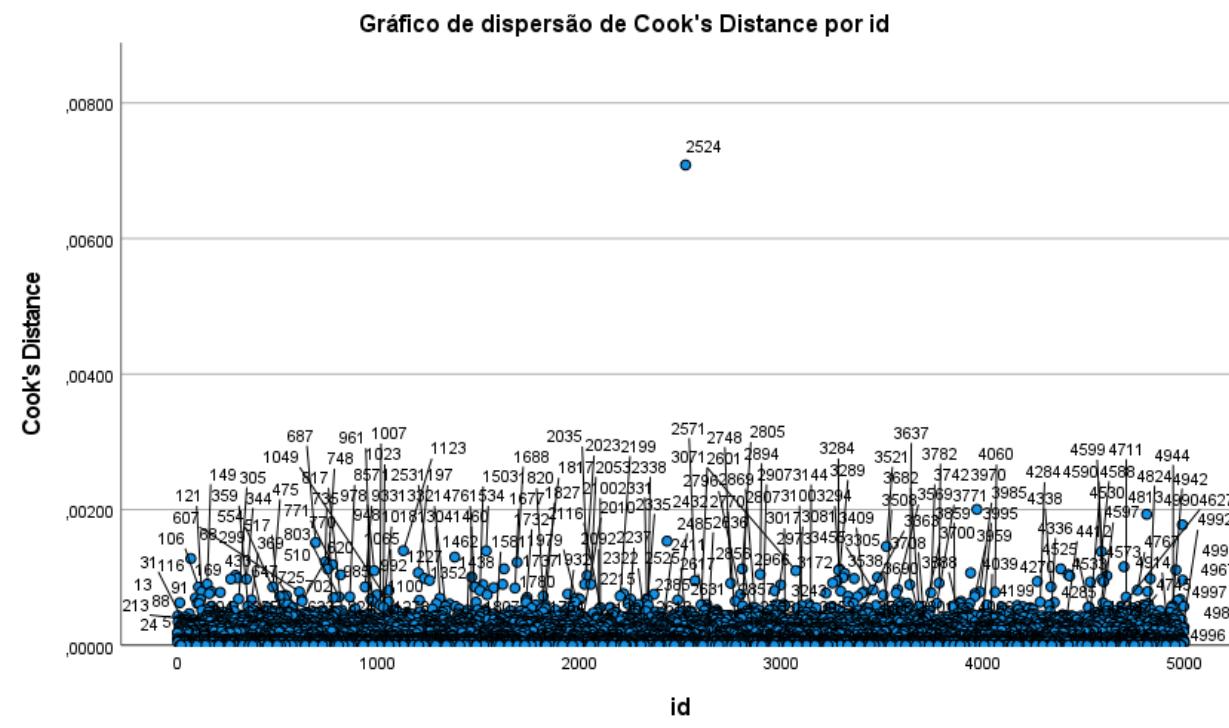


Ausência de Observações Influentes

- Reparem que o gráfico permite identificar o ID dos outliers
- Interpretação

$CD > 4/n \rightarrow$ Caso Influente

- Neste caso, o valor de corte é 0.008 (4 / 5000)
- Neste caso não há observações acima do valor de corte.
- Cumpre-se o pressuposto da ausência de observações influentes



ANÁLISE DE DADOS EM GRH

Reportar os resultados do estudo dos pressupostos

Foram realizados uma série de análises para averiguar a adequabilidade do modelo de regressão linear para o estudo destas relações, sendo que todos os pressupostos assumidos com a aplicação deste técnica foram validados. Em primeiro lugar, analisou-se graficamente a linearidade das relações entre as variáveis independentes (experiência e desempenho) com a variável dependente, tendo sido possível observar relações tendencialmente lineares, especialmente entre desempenho e rendimento (Figura x). Apurou-se também a ausência de multicolinearidade entre as variáveis independentes e de controlo com recurso às medidas VIF (<3). Posteriormente, analisou-se a distribuição dos resíduos do modelo, observando-se uma distribuição normal, com um média em torno do valor zero, e com uma variância relativamente constante ao longo dos valores previstos do modelo (Figura x). Os resultados do teste Durbin-Watson, sugerem a ausência de autocorrelação significativa nos resíduos ($D-W=2$). Apurou-se ainda a existência de observações influentes com a Distância de Cook, admitindo os valores acima de 0,008 (4/N) como indicadores de observações influentes, não tendo sido detetados casos potencialmente problemáticos à estimação do modelo.

ANÁLISE DE DADOS EM GRH

Ainda com tempo?

Repetimos o exercício com o caso da aula passada,
incluído a educação no modelo.