

# Data analysis and hypothesis testing

Suwanna Sayruamyat

BA603

# Individual assignment

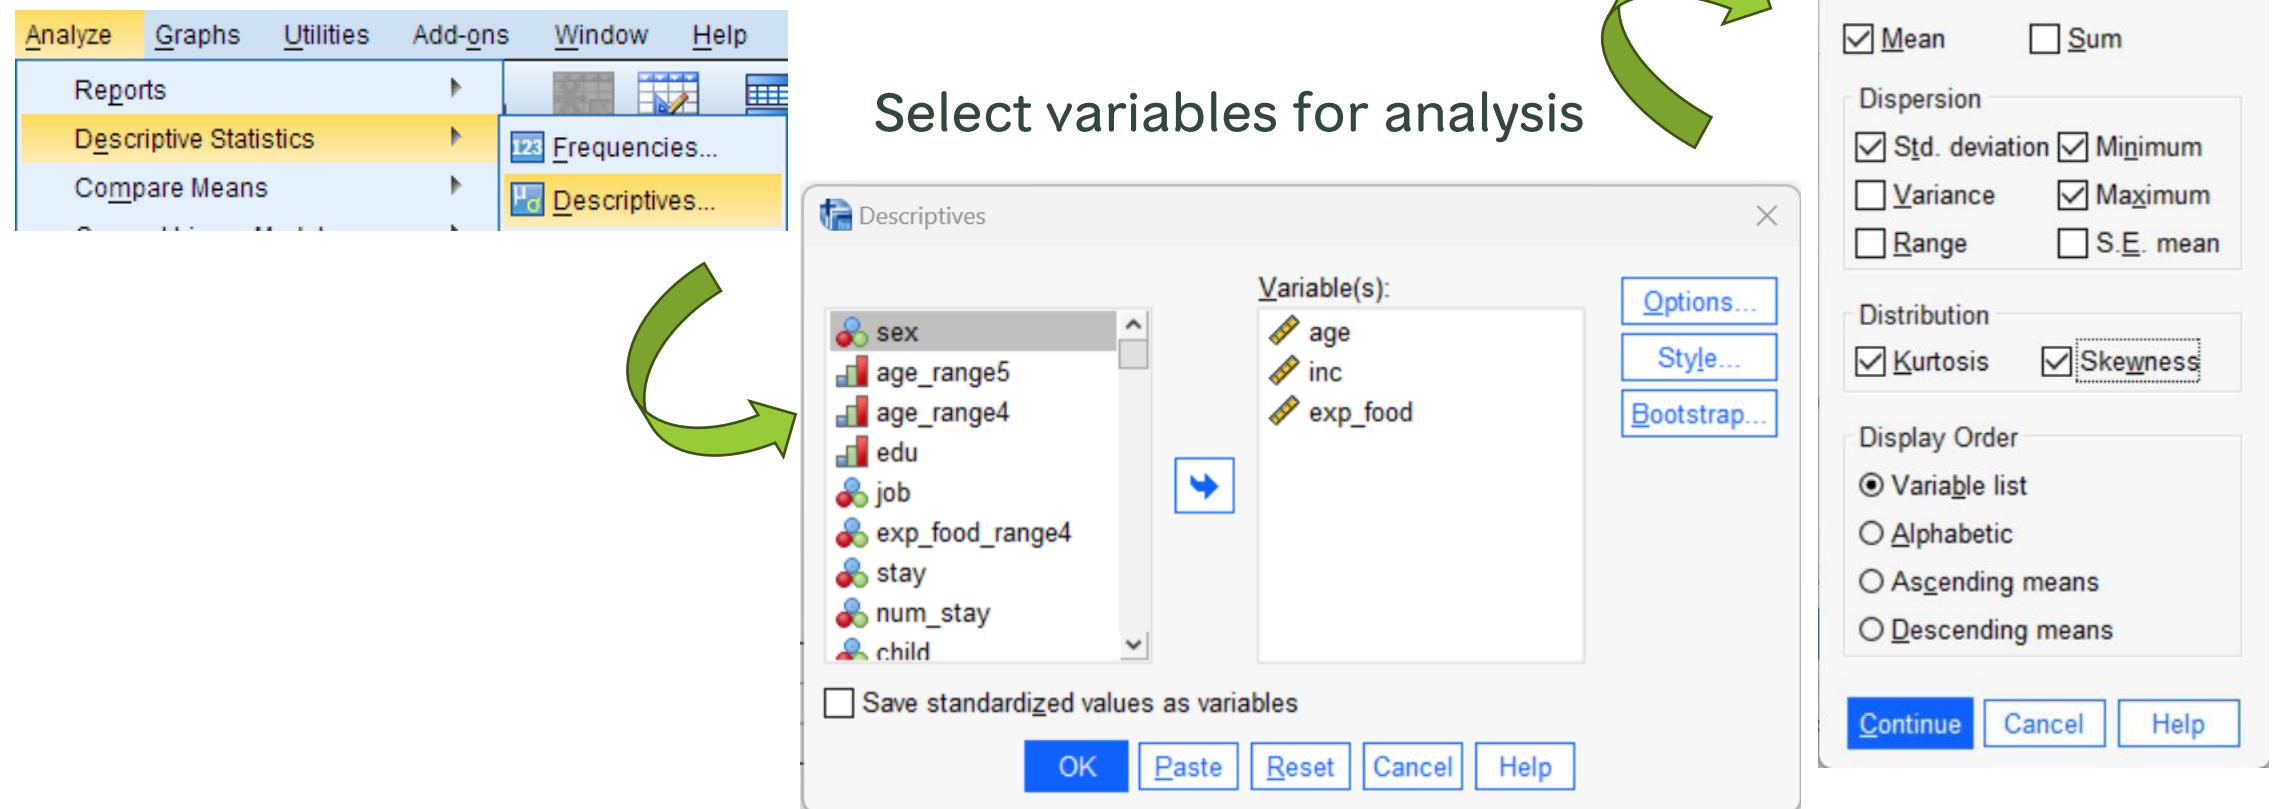
- Using file: BA603 แบบสำรวจการบริโภคนี้อ้ววและสเต็ก 2568 (Responses)
  1. Cleaning data
  2. สร้าง Data dic sheet
    - 1) ตั้งชื่อตัวแปร
    - 2) กำหนด code ของแต่ละตัวแปร
  3. สร้าง Databased ใน excel
  4. สร้าง Databased ใน spss
  5. นำเสนอข้อมูลด้วยสถิติเบื้องต้น เช่น ร้อยละ ค่าเฉลี่ย รูปภาพ และอธิบายพอสั้นๆ

# Descriptive statistics

- When summarizing quantitative (continuous/interval/ratio) variables, we are typically interested in questions like:
  - What is the "center" of the data? (Mean, median)
  - How spread out is the data? (Standard deviation/variance)
  - What are the extremes of the data? (Minimum, maximum; Outliers)
  - What is the "shape" of the distribution? Is it symmetric or asymmetric? Are the values mostly clustered about the mean, or are there many values in the "tails" of the distribution? (Skewness, kurtosis)

# Descriptives

- To run the Descriptives procedure, select Analyze > Descriptive Statistics > Descriptives.



# Descriptives

## Descriptive Statistics

# ค่าความเบี้ย (Skewness)

## ค่าความเบี้ยเป็นบวก (Positive Skewness)

- ข้อมูลมีการกระจายตัวเอียงไปทางด้านขวา
- หางของกราฟจะยาวไปทางด้านขวา
- ค่าเฉลี่ย (Mean) จะมีค่ามากกว่าค่ามัธยฐาน (Median) และค่าฐานนิยม (Mode)
- ข้อมูลส่วนใหญ่จะกระจุกตัวอยู่ทางด้านซ้าย

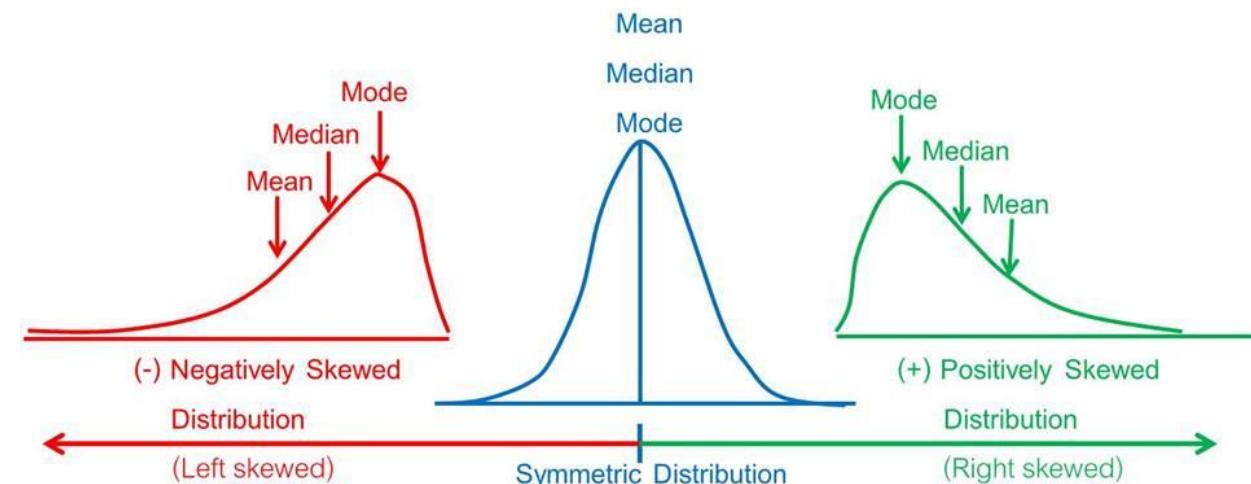
## ค่าความเบี้ยเป็นลบ (Negative Skewness)

- ข้อมูลมีการกระจายตัวแบบสมมาตร (Symmetrical Distribution)
- กราฟจะมีรูปร่างเป็นระฆังคัว (Bell-shaped)
- ค่าเฉลี่ย (Mean), ค่ามัธยฐาน (Median) และค่าฐานนิยม (Mode) จะมีค่าเท่ากัน

ค่าความเบี้ย (Skewness) คือ ค่าที่ใช้วัดความไม่สมมาตรของการกระจายตัวของข้อมูล ซึ่งจะบอกเราว่าข้อมูลมีการกระจายตัวเอียงไปทางด้านใดด้านหนึ่งหรือไม่

## ค่าความเบี้ยเป็นลบ (Negative Skewness)

- ข้อมูลมีการกระจายตัวเอียงไปทางด้านซ้าย
- หางของกราฟจะยาวไปทางด้านซ้าย
- ค่าเฉลี่ย (Mean) จะมีค่าน้อยกว่าค่ามัธยฐาน (Median) และค่าฐานนิยม (Mode)
- ข้อมูลส่วนใหญ่จะกระจุกตัวอยู่ทางด้านขวา



# ค่าความโด่ง (Kurtosis)

## Mesokurtic (ความโด่งปกติ)

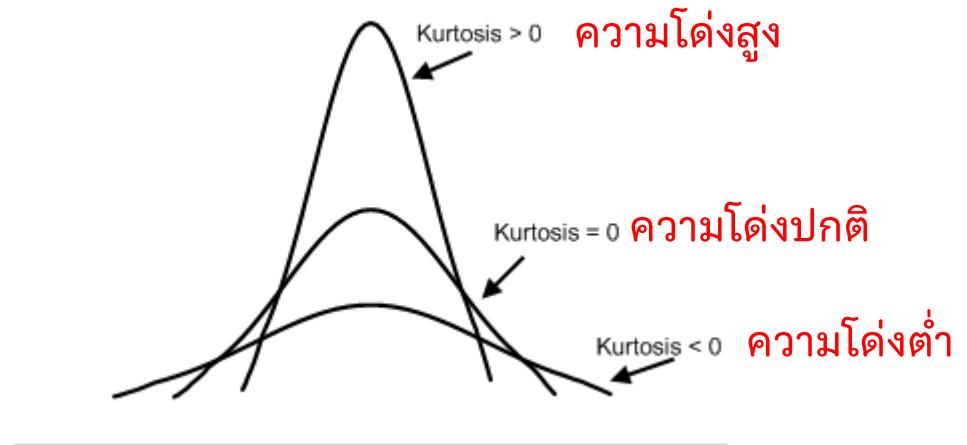
- เป็นการแจกแจงที่มีความโด่งปกติ คล้ายกับการแจกแจงแบบปกติ (Normal distribution)
- ค่าความโด่งมีค่าประมาณ 3 หรือ 0 (ขึ้นอยู่กับการคำนวณ)

## Platykurtic (ความโด่งต่ำ)

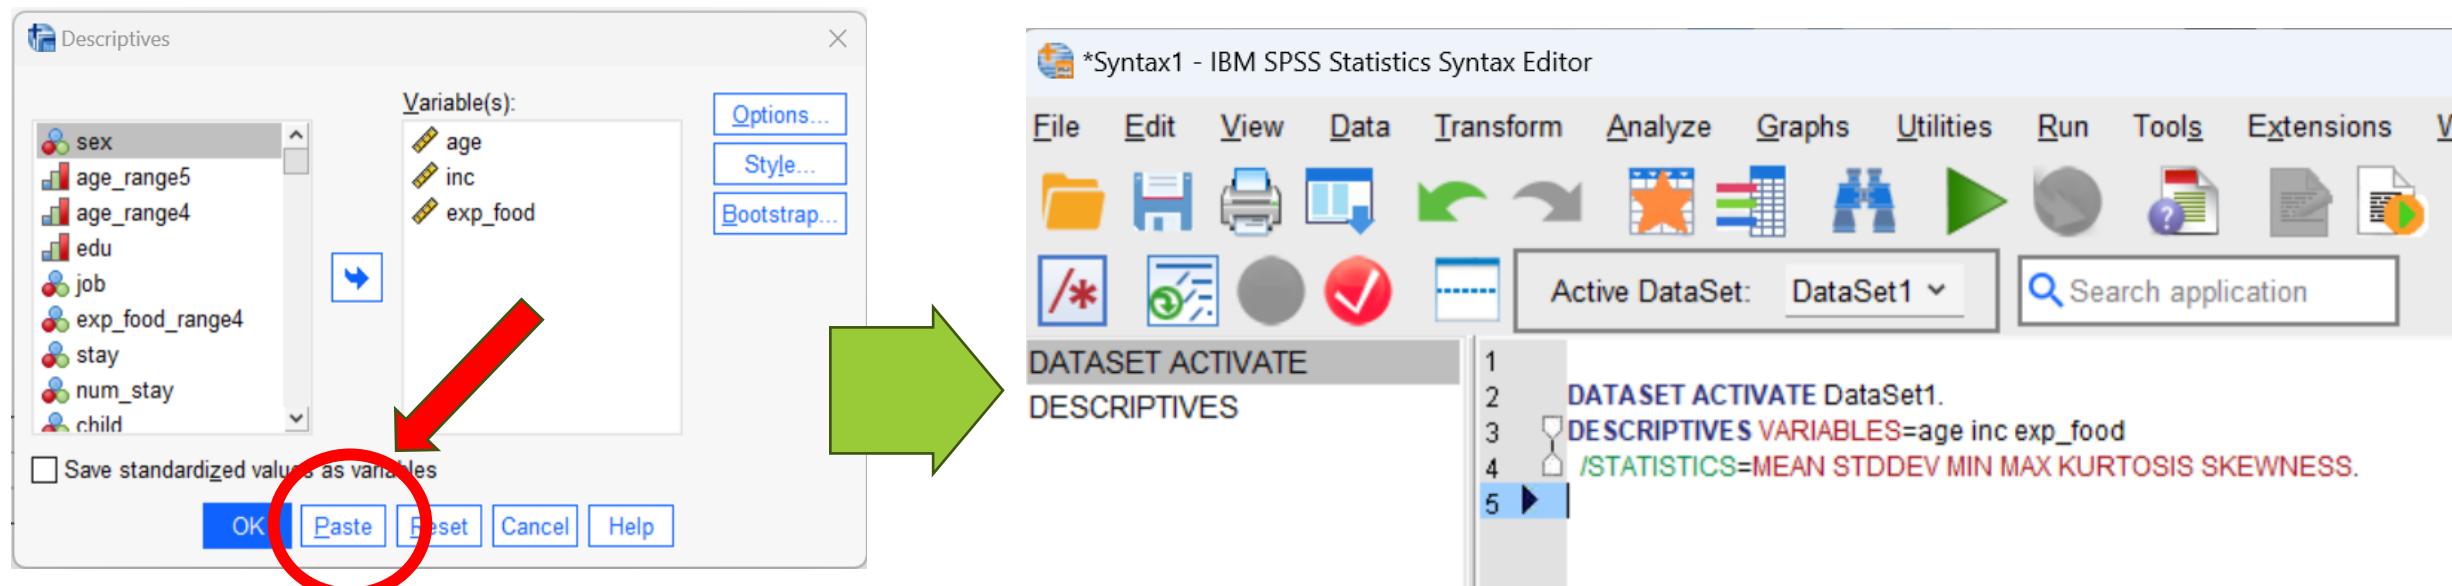
- เป็นการแจกแจงที่มีความโด่งต่ำ ยอดแบน และหางบาง
- ข้อมูลมีการกระจายตัวค่อนข้างสม่ำเสมอ และมีข้อมูลที่ห่างจากค่าเฉลี่ยน้อยกว่าการแจกแจงแบบปกติ
- ค่าความโด่งมีค่าน้อยกว่า 3 หรือน้อยกว่า 0

## Leptokurtic (ความโด่งสูง)

- เป็นการแจกแจงที่มีความโด่งสูง ยอดแหลม และหางหนามีข้อมูลกระจุกตัวอยู่บริเวณค่าเฉลี่ยมาก และมีข้อมูลที่ห่างจากค่าเฉลี่ยมาก (Outliers) 多于 มากกว่าการแจกแจงแบบปกติค่าความโด่งมีค่ามากกว่า 3 หรือมากกว่า 0



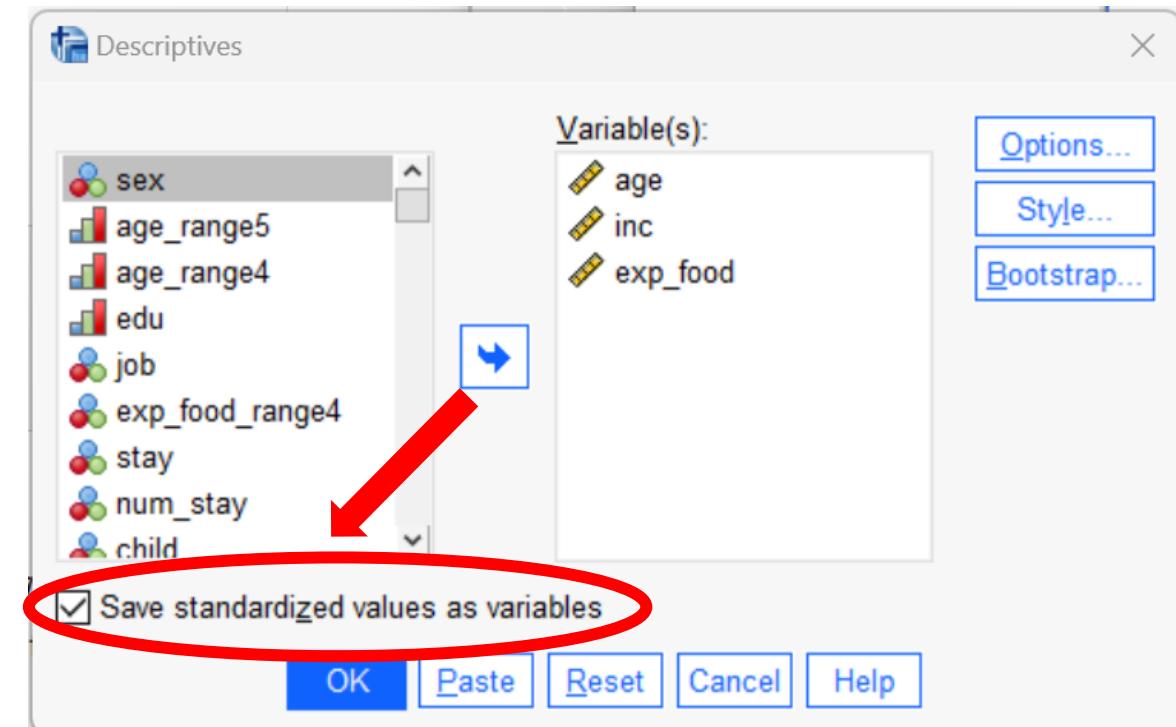
# Using Syntax



# Compute standardized scores (Z-score) for numeric variables

## Using the Descriptives Dialog Window

1. Click Analyze > Descriptive Statistics > Descriptives.
2. Add the variables *age*, *inc* and *exp\_food* to the Variables box.
3. Check the box **Save standardized values as variables**.
4. Click OK when finished.

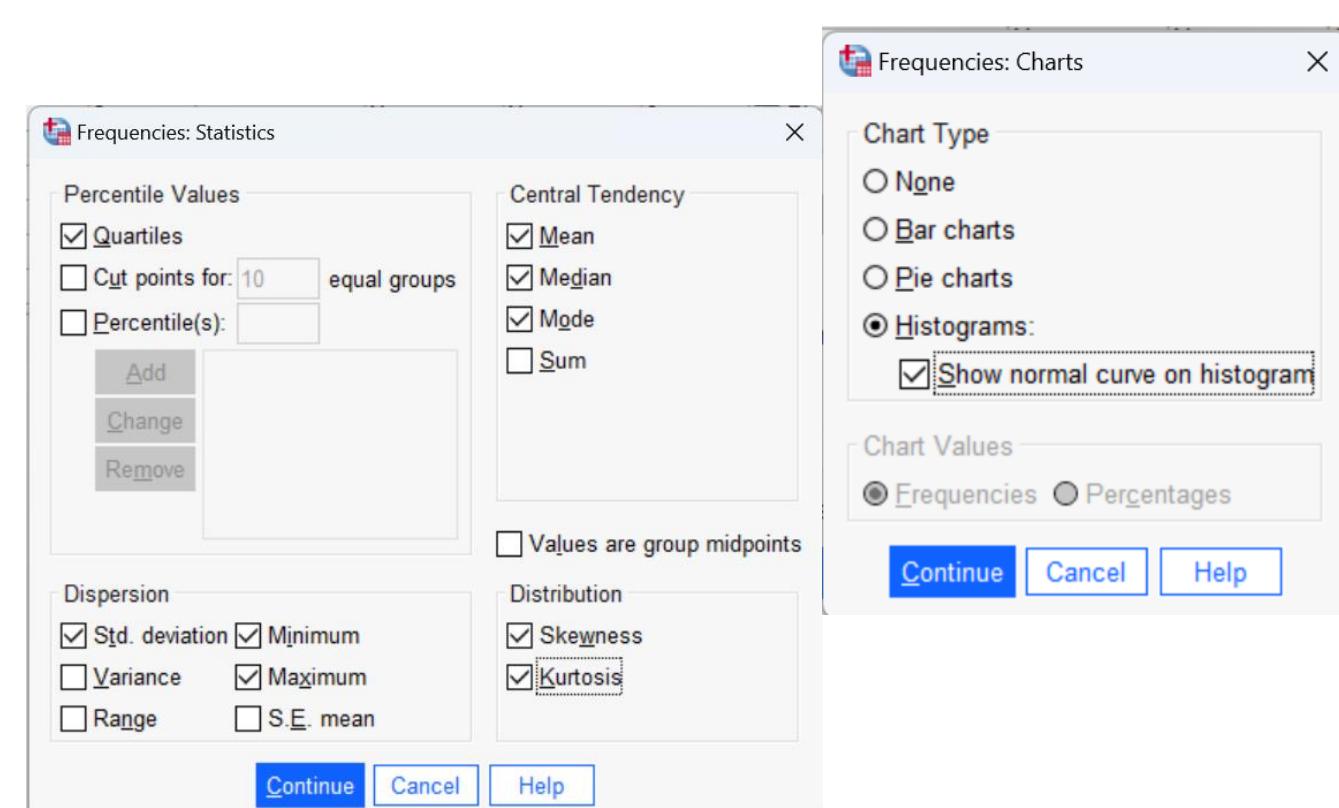
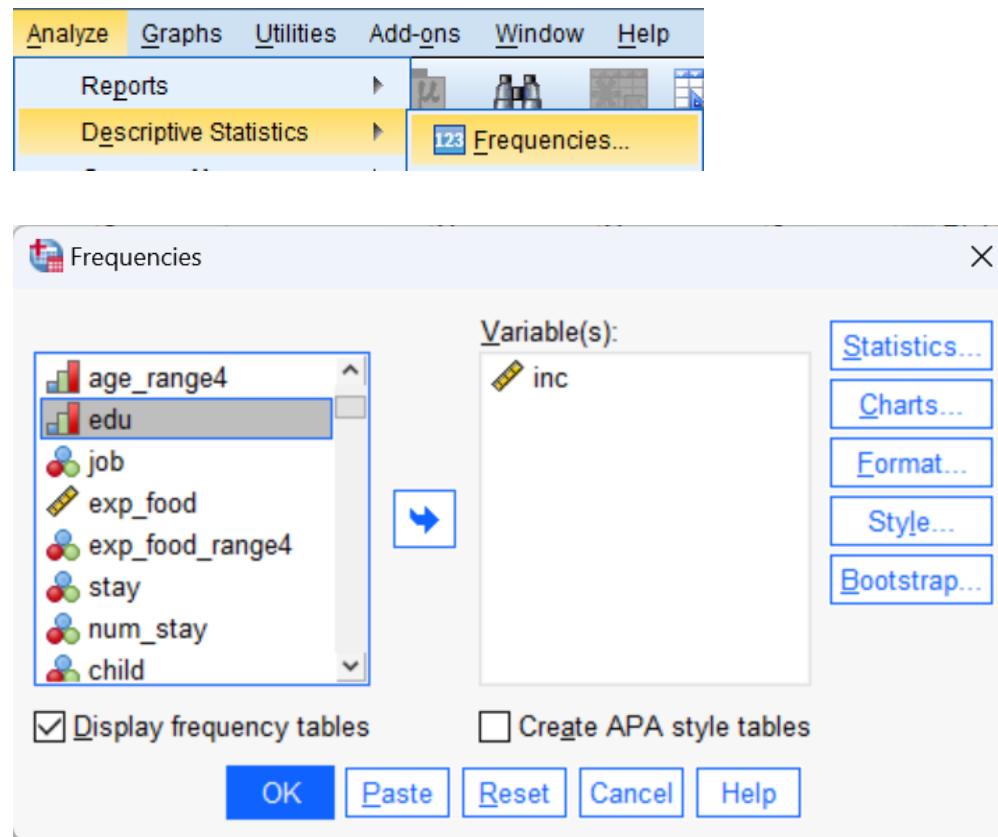


ค่า Z-score ของตัวแปรที่ต้องการจะเพิ่มใน variable lists

83	avg_PBC	Numeric	8	2			None	None	10	Right	Scale	Input
84	avg_INT	Numeric	8	2			None	None	10	Right	Scale	Input
85	avg_AVAI	Numeric	8	2			None	None	10	Right	Scale	Input
86	avg_HC	Numeric	0	2			None	None	10	Right	Scale	Input
87	Zage	Numeric	11	5	Zscore(age)		None	None	13	Right	Scale	Input
88	Zinc	Numeric	11	5	Zscore(inc)		None	None	13	Right	Scale	Input
89	Zexp_food	Numeric	11	5	Zscore(exp_fo...)		None	None	13	Right	Scale	Input

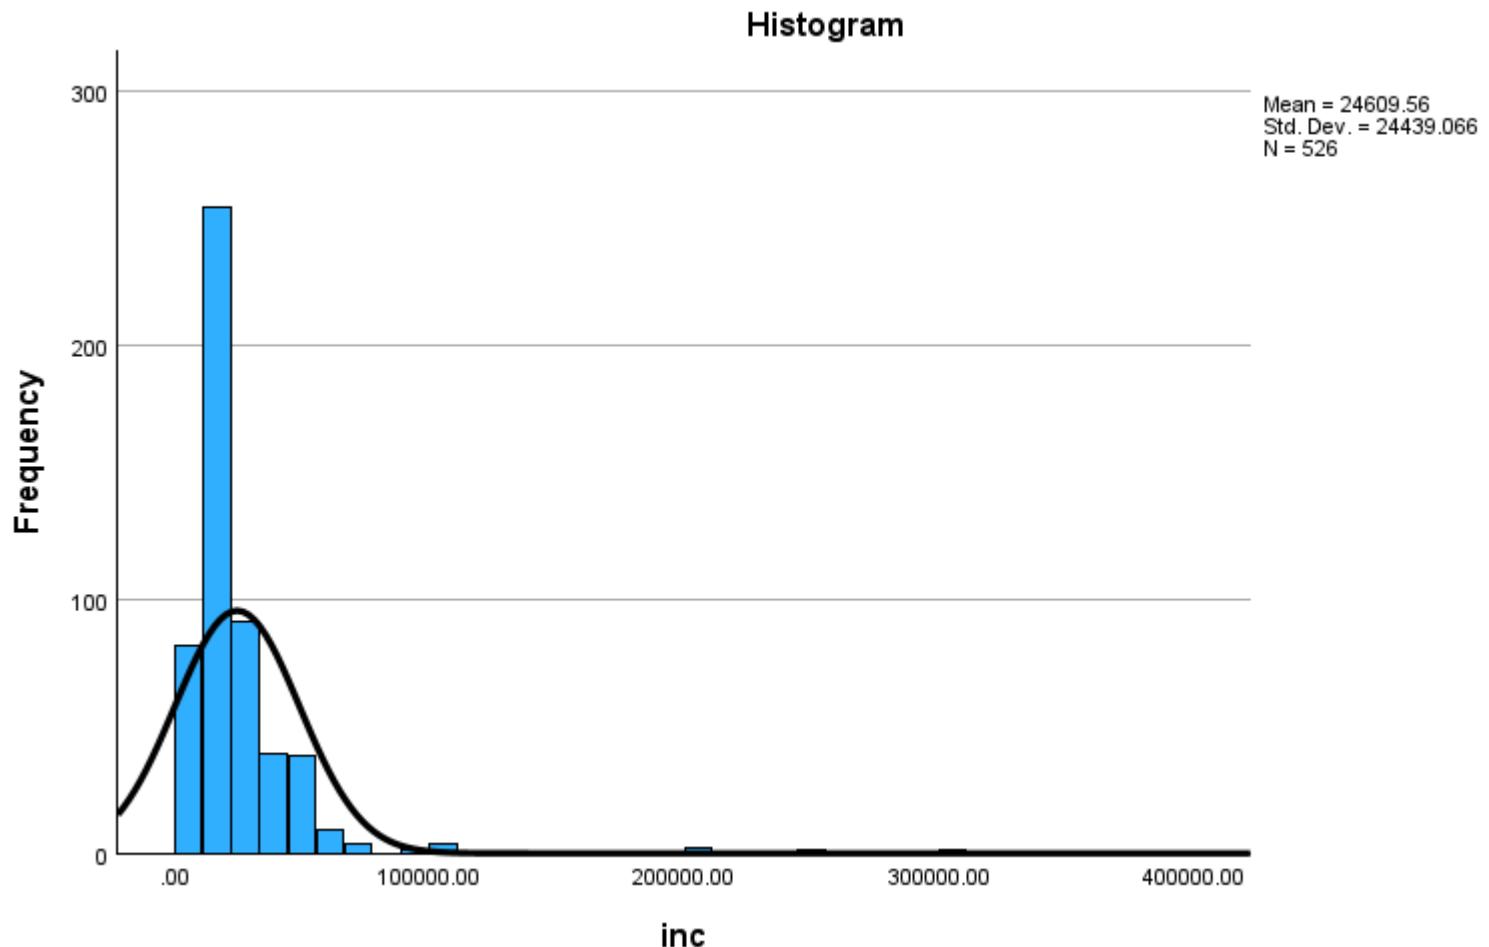
# Frequencies with Scale Variables

click Analyze > Descriptive Statistics > Frequencies.



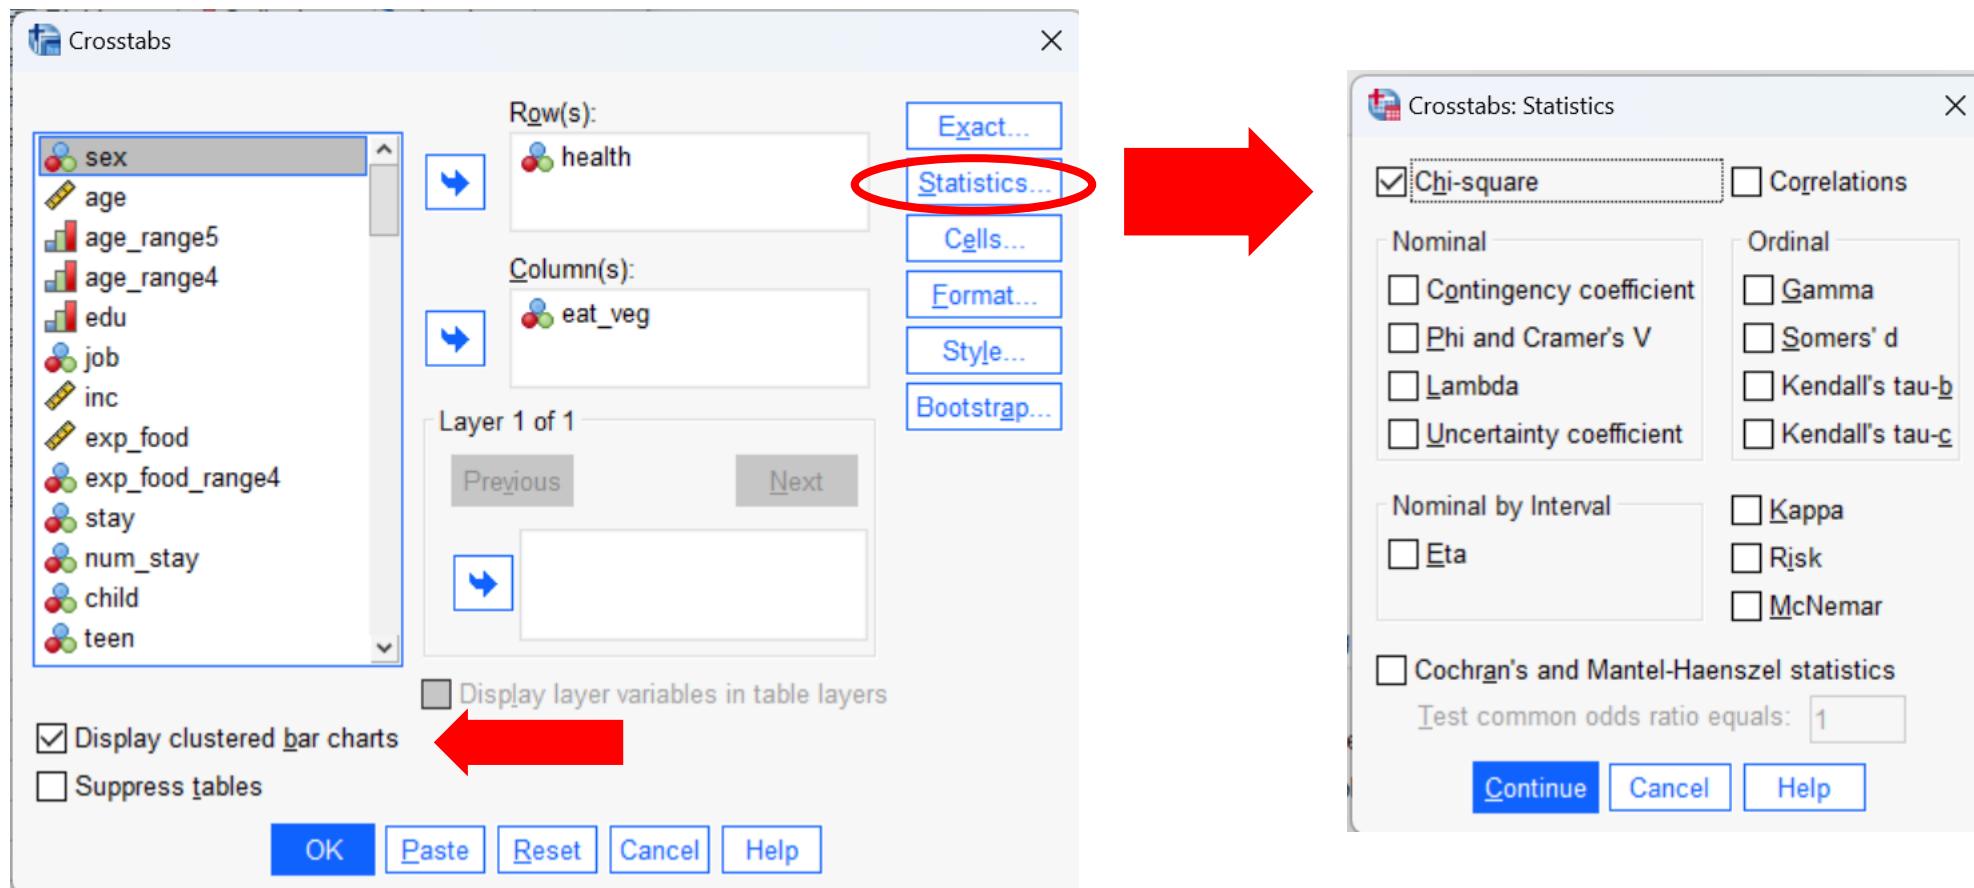
# Frequencies with Scale Variables

Statistics		
inc	Valid	526
	Missing	0
Mean	24609.5627	
Median	19000.0000	
Mode	15000.00	
Std. Deviation	24439.06623	
Skewness	6.014	
Std. Error of Skewness	.106	
Kurtosis	53.336	
Std. Error of Kurtosis	.213	
Minimum	600.00	
Maximum	300000.00	
Percentiles	25	15000.0000
	50	19000.0000
	75	30000.0000



# Crosstabs: Two categorical variables.

- To create a crosstab, click Analyze > Descriptive Statistics > Crosstabs.



# Crosstabs: output

## health \* eat\_veg Crosstabulation

Count

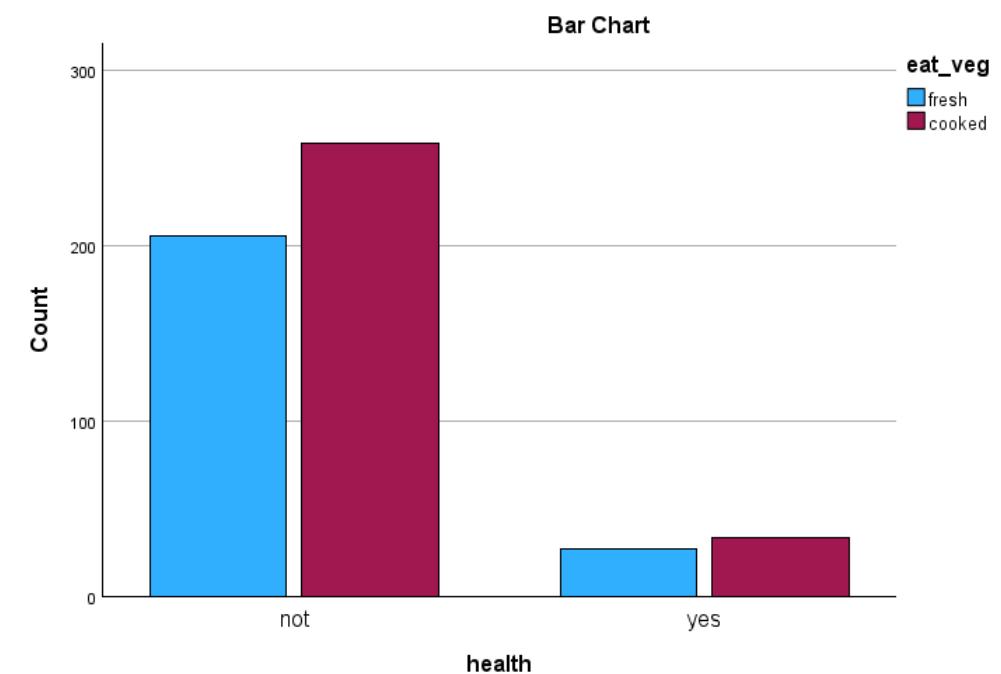
		eat_veg		Total
		fresh	cooked	
health	not	206	259	465
	yes	27	34	61
Total		233	293	526

## Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	.000 <sup>a</sup>	1	.995		
Continuity Correction <sup>b</sup>	.000	1	1.000		
Likelihood Ratio	.000	1	.995		
Fisher's Exact Test				1.000	.554
Linear-by-Linear Association	.000	1	.995		
N of Valid Cases	526				

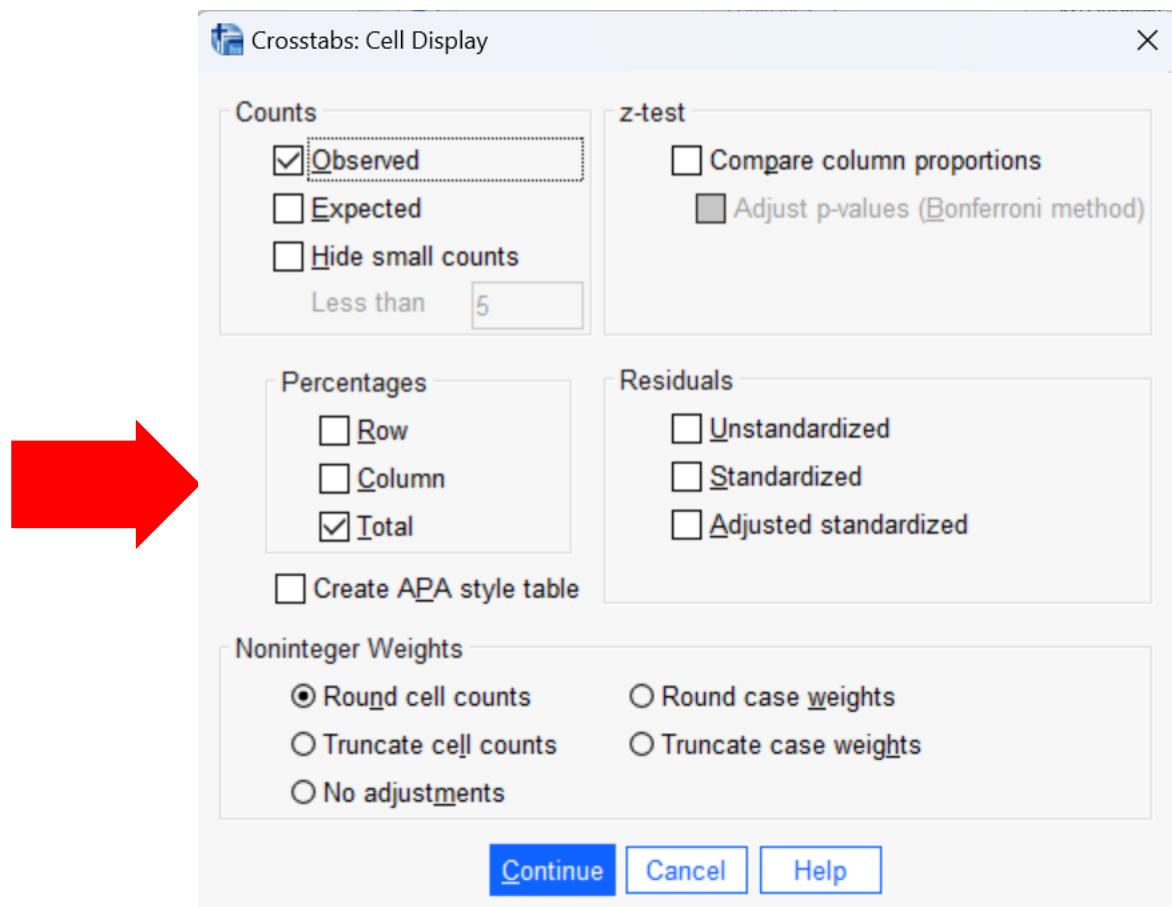
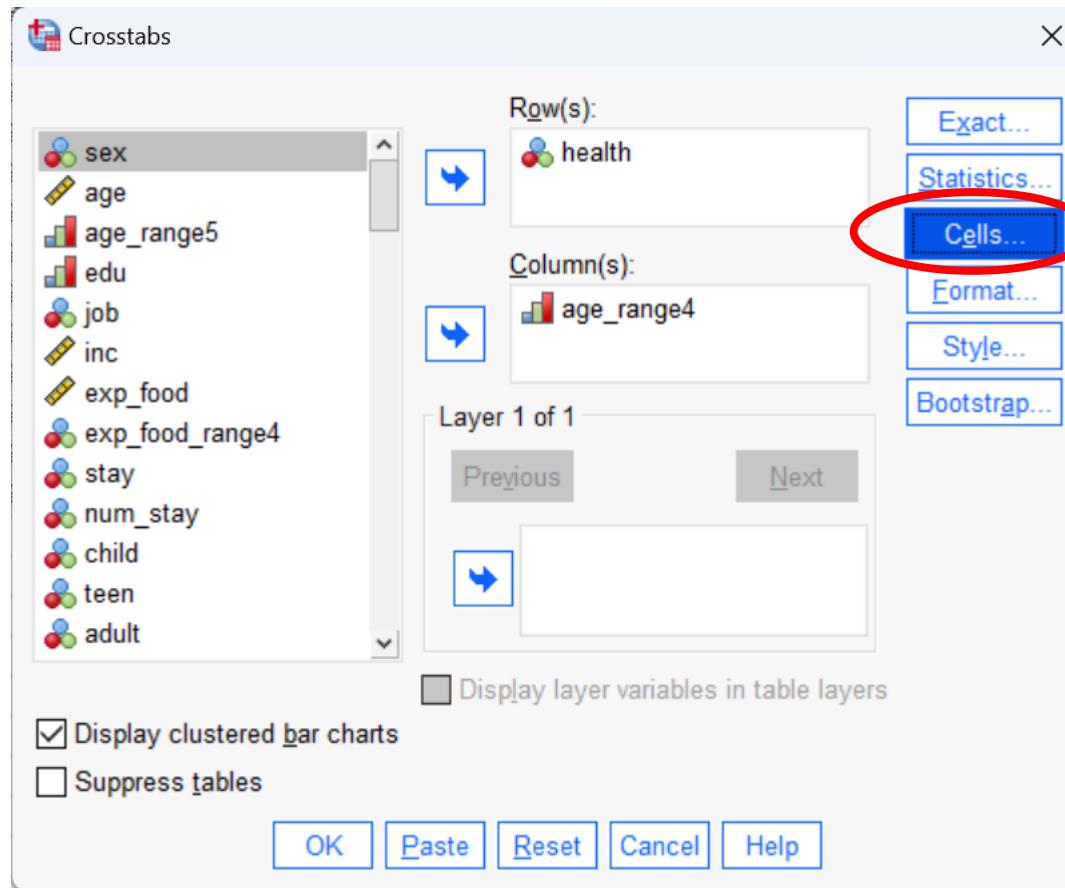
a. 0 cells (0.0%) have expected count less than 5. The minimum expected count is 27.02.

b. Computed only for a 2x2 table



BA603

# Crosstabs: Two or more categories (groups) for each variable.



# Crosstabs: Two or more categories (groups) for each variable.

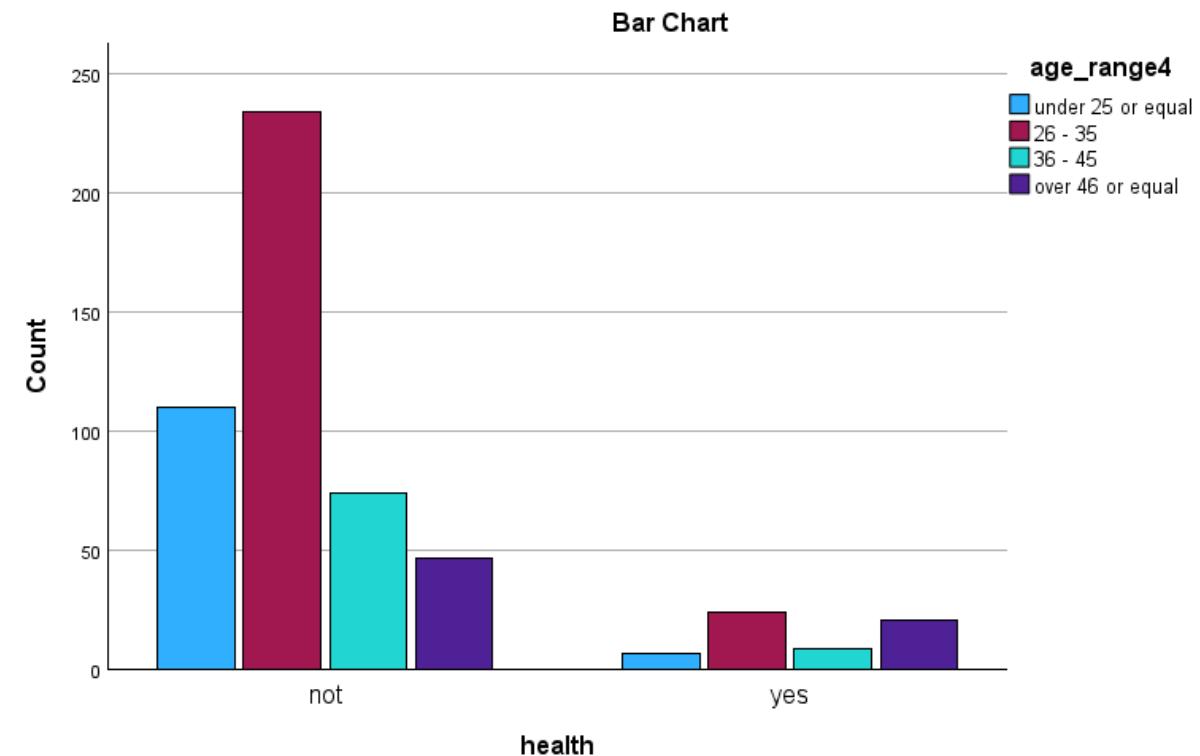
**health \* age\_range4 Crosstabulation**

		age_range4				Total	
		under 25 or equal	26 - 35	36 - 45	over 46 or equal		
health	not	Count	110	234	74	47	465
	yes	Count	7	24	9	21	61
Total		Count	117	258	83	68	526
		% of Total	22.2%	49.0%	15.8%	12.9%	100.0%

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	29.637 <sup>a</sup>	3	<.001
Likelihood Ratio	23.740	3	<.001
Linear-by-Linear Association	22.281	1	<.001
N of Valid Cases	526		

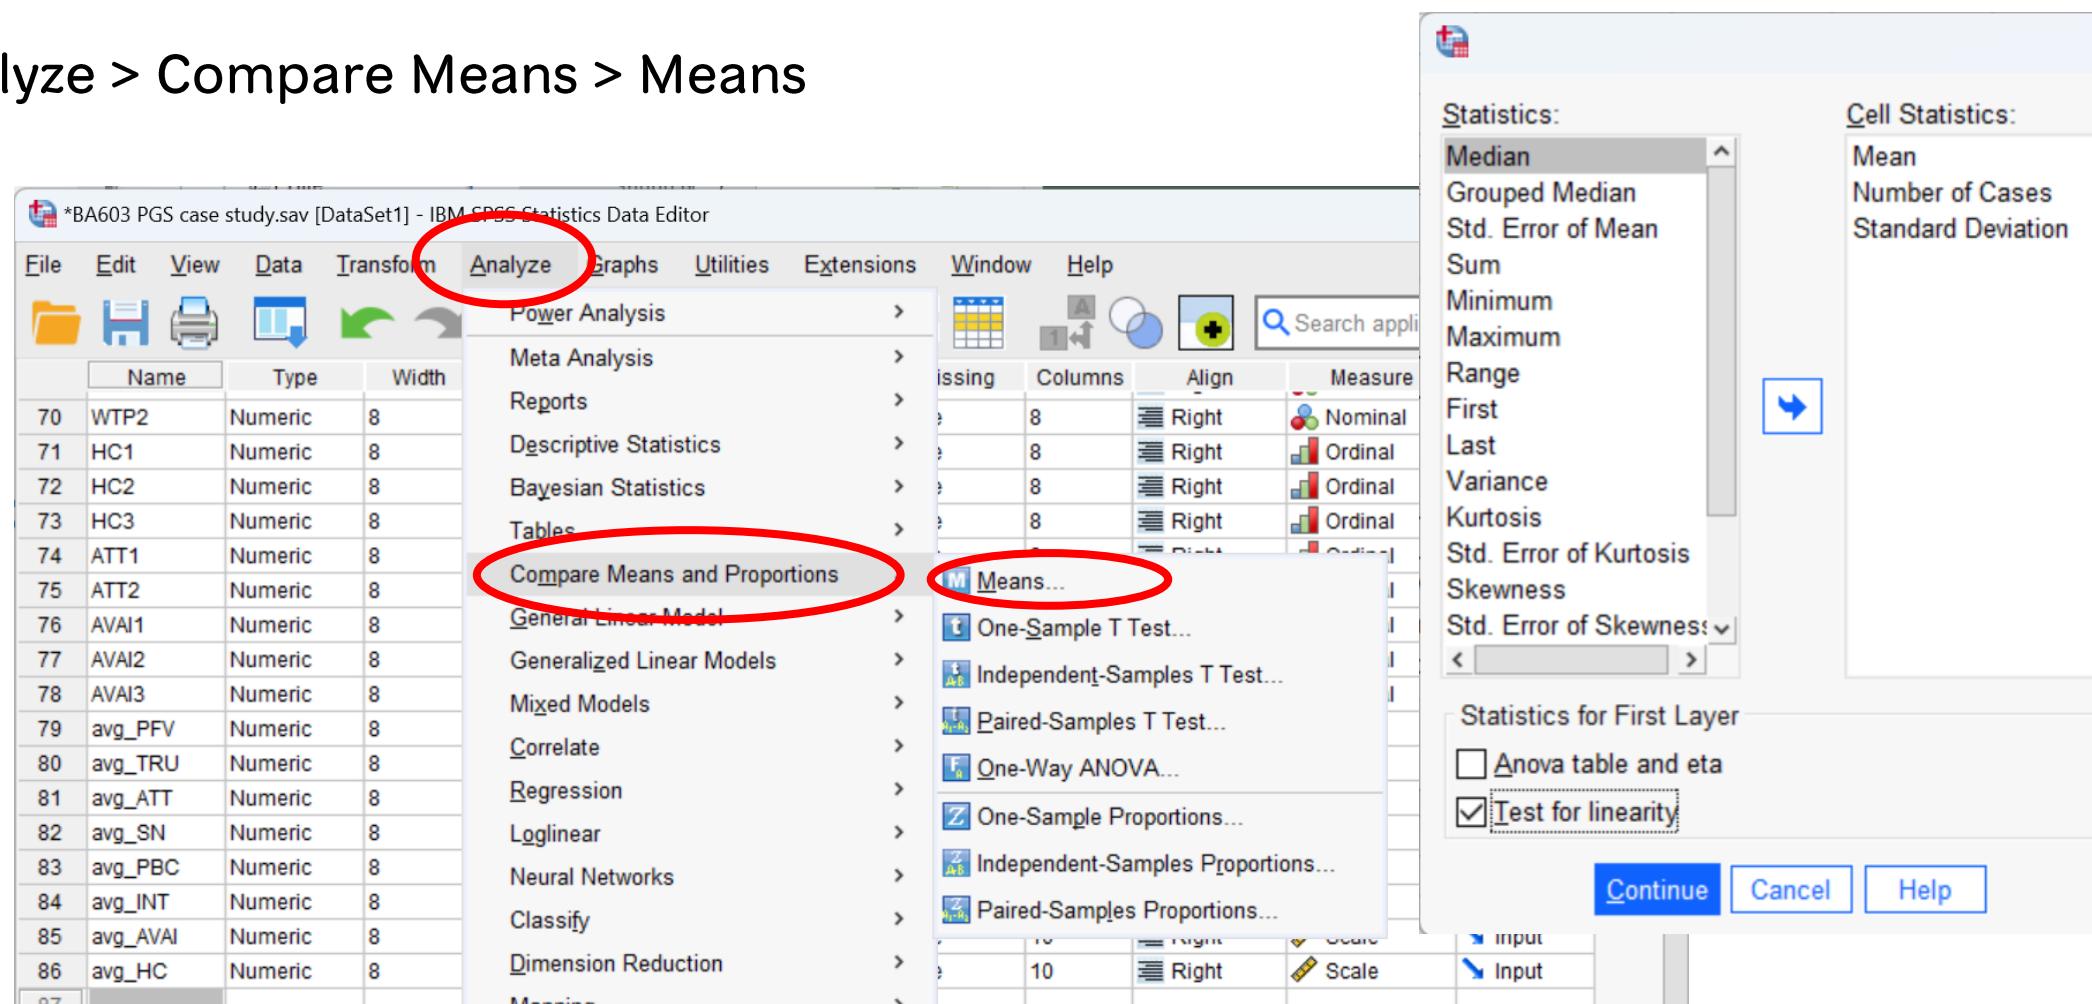
a. 0 cells (0.0%) have expected count less than 5. The minimum expected count is 7.89.



BA603

# Compare Mean: Comparing averages across related demographic variables

Click: Analyze > Compare Means > Means



# Compare Mean:

The image shows two overlapping dialog boxes from SPSS. The left dialog is titled 'Means' and has a 'Dependent List' containing 'inc' and an 'Independent List' containing 'sex'. The right dialog is titled 'Statistics' and lists various statistical measures under 'Statistics' and 'Cell Statistics'.

**Dependent List:** inc

**Independent List:** sex

**Statistics:**

- Median
- Grouped Median
- Std. Error of Mean
- Sum
- Minimum
- Maximum
- Range
- First
- Last
- Variance
- Kurtosis
- Std. Error of Kurtosis
- Skewness
- Std. Error of Skewness

**Cell Statistics:**

- Mean
- Number of Cases
- Standard Deviation

A green arrow points from the text 'ตัวแปรตามที่ต้องการเปรียบเทียบ' to the 'Dependent List' field. A red arrow points from the text 'ตัวแปรกลุ่มที่ต้องการเปรียบเทียบ' to the 'Independent List' field.

ตัวแปรตามที่ต้องการ  
เปรียบเทียบ

ตัวแปรกลุ่มที่ต้องการ  
เปรียบเทียบ

# Compare Mean: Output

## Case Processing Summary

	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
inc * sex	526	100.0%	0	0.0%	526	100.0%

## Report

inc

sex	Mean	N	Std. Deviation
male	28844.5665	173	33170.82010
female	22534.0510	353	18439.86499
Total	24609.5627	526	24439.06623

## ANOVA Table<sup>a</sup>

	Sum of Squares		df	Mean Square	F	Sig.
	Between Groups	(Combined)				
inc * sex	4623434799.9		1	4623434799.9	7.842	.005
Within Groups	3.089E+11		524	589584433.59		
Total	3.136E+11		525			

a. With fewer than three groups, linearity measures for inc \* sex cannot be computed.

## Measures of Association

	Eta	Eta Squared
inc * sex	.121	.015

- "inc \* sex" หมายถึงความสัมพันธ์ระหว่างรายได้ (inc) กับเพศ (sex)
- ค่า Eta = .121 แสดงถึง ความสัมพันธ์ในระดับที่ต่ำถึงปานกลางระหว่างรายได้และเพศ
- Eta Squared = .015 หมายถึง เพศสามารถอธิบายความผันแปรของรายได้ได้ 1.5%

# Compare Means: Test for linearity

- ค่าสัมประสิทธิ์อีต้า ( $\eta$ ) เป็นค่าสถิติที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรสองตัว เมื่อตัวแปรหนึ่งเป็นตัวแปรเชิงกลุ่ม (categorical variable) และอีกตัวแปรหนึ่งเป็นตัวแปรเชิงปริมาณ (continuous variable)
- ค่า Eta จะอยู่ในช่วง 0 ถึง 1
  - 0 หมายถึงไม่มีความสัมพันธ์
  - 1 หมายถึงมีความสัมพันธ์สมบูรณ์แบบ
  - Eta จะคล้ายกับค่าสัมประสิทธิ์สหสัมพันธ์ (correlation coefficient) แต่ใช้ในการนวีที่ตัวแปรหนึ่งเป็นเชิงกลุ่ม

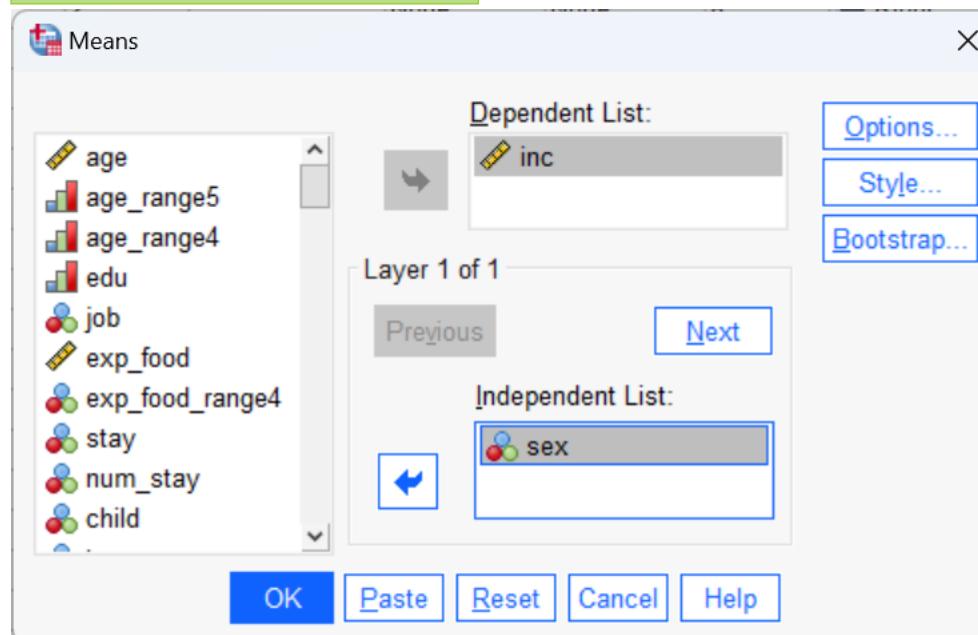
## Measures of Association

	Eta	Eta Squared
inc * sex	.121	.015

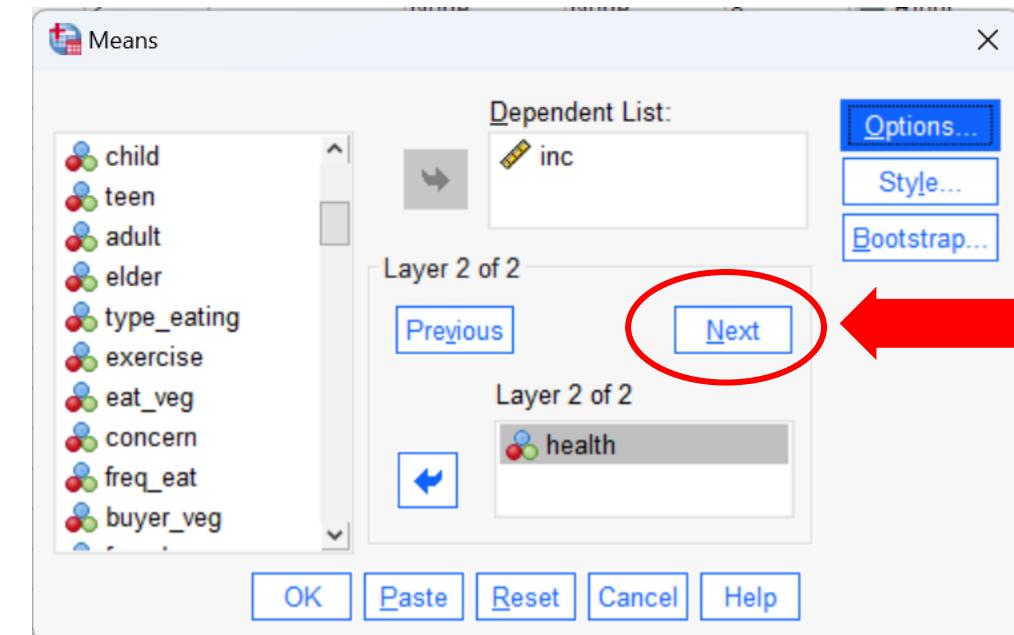
- "inc \* sex" หมายถึงความสัมพันธ์ระหว่างรายได้ (inc) กับเพศ (sex)
- ค่า Eta = .121 แสดงถึง ความสัมพันธ์ในระดับที่ต่ำถึงปานกลางระหว่างรายได้และเพศ
- Eta Squared = .015 หมายถึง เพศสามารถอธิบายความผันแปรของรายได้ได้ 1.5%

# Compare Means for 2 layers

Layer 1: sex



Layer 2: health



# Compare Means for 2 layers: output

## Report

inc	sex	health	Mean	N	Std. Deviation
male	not	28913.3333	156	34482.19753	
	yes	28213.5294	17	17582.41271	
	Total	28844.5665	173	33170.82010	
female	not	22012.3301	309	18376.12966	
	yes	26197.9545	44	18682.91292	
	Total	22534.0510	353	18439.86499	
Total	not	24327.5054	465	25139.32745	
	yes	26759.6721	61	18259.82794	
	Total	24609.5627	526	24439.06623	

**ANOVA Table<sup>a</sup>**

inc * sex	Between Groups	(Combined)	Sum of Squares	df	Mean Square	F	Sig.
		4623434799.9	1	4623434799.9	7.842	.005	
	Within Groups		3.089E+11	524	589584433.59		
	Total		3.136E+11	525			

a. With fewer than three groups, linearity measures for inc \* sex cannot be computed.

## Measures of Association

	Eta	Eta Squared
inc * sex	.121	.015

ผลส่วนนี้จะเหมือนกับ Layer 1

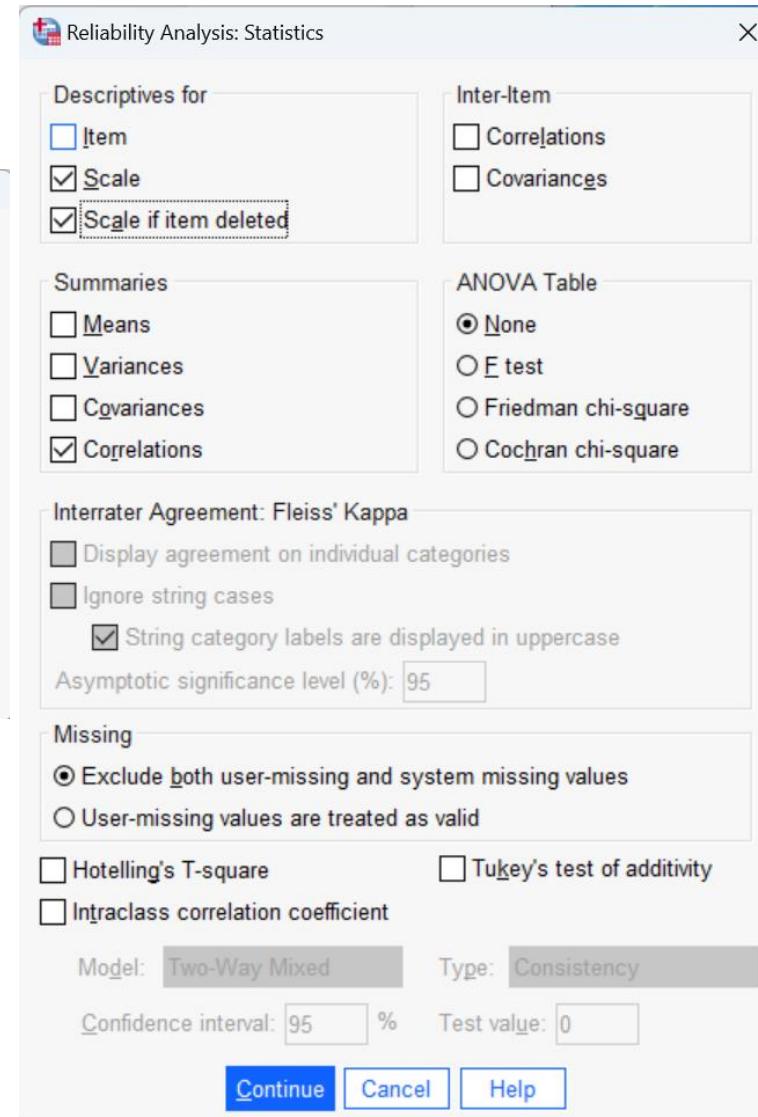
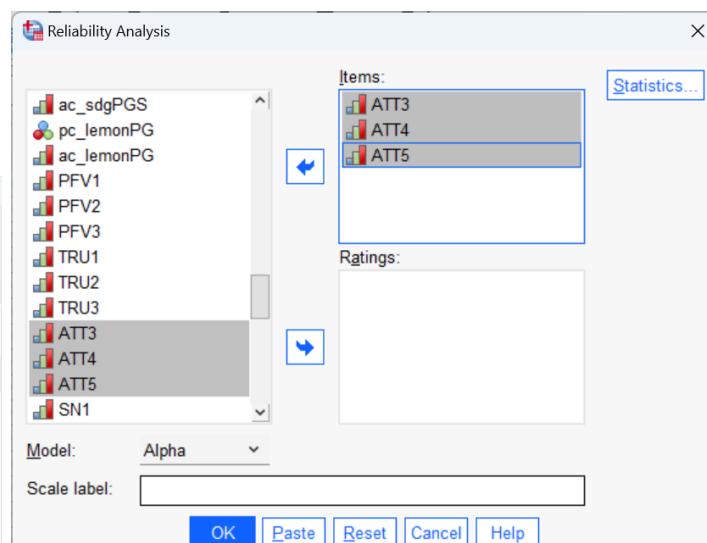
BA603

# Reliability test (Cronbach's alpha coefficient)

1. Click: Analyze > Scale > Reliability Analysis...
2. เลือกตัวแปรที่ต้องการทดสอบ
3. Click: Statistics
4. เลือกค่าสถิติที่ต้องการ
5. Click: Continue

The screenshot shows the IBM SPSS Statistics Data Editor interface. The menu bar includes File, Edit, View, Data, Transform, Analyze, Graphs, Utilities, Extensions, Window, and Help. The 'Analyze' menu is open, showing options like Power Analysis, Meta Analysis, Reports, Descriptive Statistics, Bayesian Statistics, Tables, Compare Means and Proportions, General Linear Model, Generalized Linear Models, Mixed Models, Correlate, Regression, Loglinear, Neural Networks, Classify, Dimension Reduction, Mapping, Scale, Nonparametric Tests, Forecasting, Survival, Multiple Response, Missing Value Analysis..., Multiple Imputation, Complex Samples, Simulation..., Quality Control, Unicode:ON, and Classic.

The main area displays a data view with 24 rows and several columns of numerical data. The columns include sex, age, and various scale items such as ac\_sdgPGS, pc\_lemonPG, ac\_lemonPG, PFV1, PFV2, PFV3, TRU1, TRU2, TRU3, ATT3, ATT4, ATT5, and SN1. The 'Data View' tab is selected at the bottom.



# Reliability test (Cronbach's alpha coefficient)

Scale: ALL VARIABLES

Case Processing Summary		
	N	%
Cases	Valid	526 100.0
	Excluded <sup>a</sup>	0 .0
Total		526 100.0

a. Listwise deletion based on all variables in the procedure.

Reliability Statistics	
Cronbach's Alpha	N of Items
.914	3

Item-Total Statistics				
Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Cronbach's Alpha if Item Deleted	
ATT3	8.2319	2.544	.825	.879
ATT4	8.2034	2.471	.876	.836
ATT5	8.0932	2.645	.783	.913

Scale Statistics			
Mean	Variance	Std. Deviation	N of Items
12.2643	5.509	2.34714	3

Cronbach's alpha coefficient

ช่วยพิจารณาการตัดข้อคำถาม

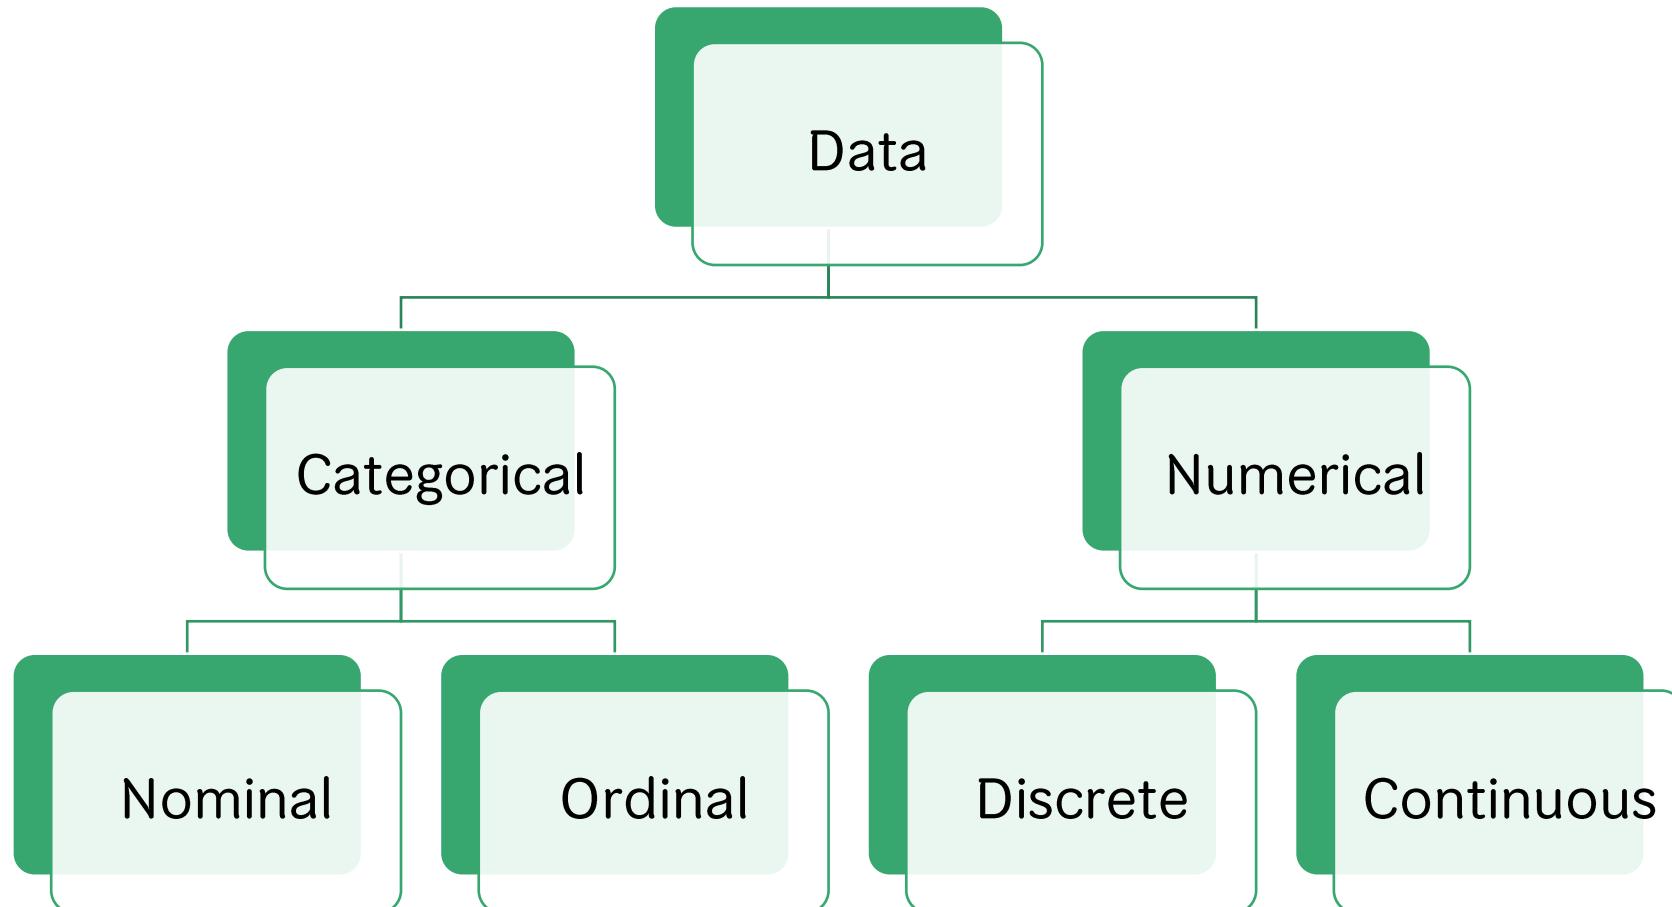
There are no universally agreed-upon "perfect" cutoffs, but general guidelines are often used:

**Cronbach's alpha**

**Meaning**

$\alpha \geq 0.9$	Excellent internal consistency
$0.8 \leq \alpha < 0.9$	Good internal consistency
$0.7 \leq \alpha < 0.8$	Acceptable internal consistency
$0.6 \leq \alpha < 0.7$	Questionable internal consistency
$0.5 \leq \alpha < 0.6$	Poor internal consistency.
$\alpha < 0.5$	Unacceptable internal consistency

# Type of data



# Types of Data Analysis

## Descriptive

ความถี่ ร้อยละ  
ค่าเฉลี่ย ส่วน  
เบี่ยงเบนมาตรฐาน  
ความแปรปรวน

## Comparative

### T-test



Independent t-test

$H_0:$  mean G1 = mean G2  
 $H_a:$  mean G1  $\neq$  mean G2

### One-way ANOVA



Post Hoc Comparisons

$H_0:$  two groups mean equal  
 $H_a:$  two groups mean not equal

One-way ANOVA

$H_0:$  all group means equal  
 $H_a:$  at least one group different

## Associative

### Correlation

$H_0:$  no linear relationship bet Two variables  
 $H_a:$  there is linear relationship bet two variables  
\* Correlation does not imply causation

## Predictive

### Regression

$H_0:$  all coeff. = 0  
 $H_a:$  at least one coif.  $\neq$  0

### Crosstabulation

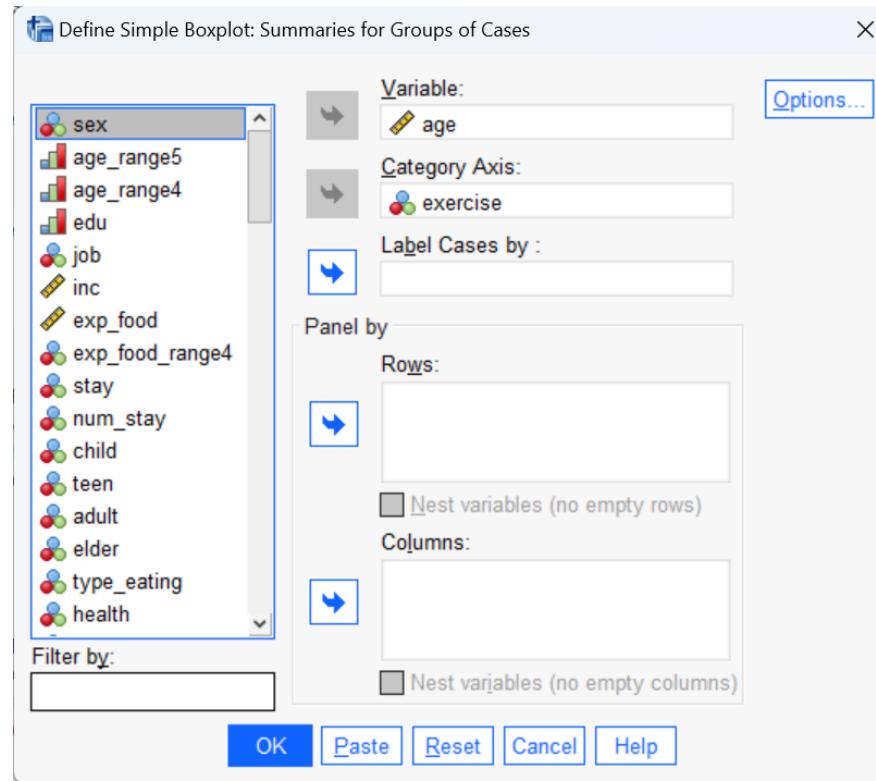
$H_0:$  no relationship bet Two variables  
 $H_a:$  there is relationship bet two variables

Chi-square test

### Structural Equation modelling (SEM)

# Boxplot

**EXAMINE VARIABLES=age BY exercise  
/PLOT=BOXPLOT  
/STATISTICS=NONE  
/NOTOTAL.**



เปรียบเทียบอายุระหว่างกลุ่มคนที่ออกกำลังกาย

