



Basic Stata and biostatistics for DNCD

THANANAN JIVARAMONAIKUL, MD.

Outline

2



1. Import file, open file, save file, save command, ปรับแต่งหน้าตา
2. Type of data and data management
3. Study design : cross-sectional, case-control, cohort
4. Type of statistic :
 - ▶ Descriptive: means, S.D., median, quarter, IQR
 - ▶ Analytic : comparison, association
5. Measure in epidemiology
 - ▶ Frequency : prevalence, incidence
 - ▶ Comparison : Chi2 test, t-test, Wilcoxon test
 - ▶ Association : RR, OR, Regression (linear, logistic, Poisson)
6. Confounding & effect modification



History

Filter commands here

Command _rc

There are no items to show.

 (R)
16.0
Statistics/Data Analysis
MP - Parallel Edition

Copyright 1985-2019 StataCorp LLC
StataCorp
4905 Lakeway Drive
College Station, Texas 77845 USA
800-STATA-PC <http://www.stata.com>
979-696-4600 stata@stata.com
979-696-4601 (fax)

30-student 2-core Stata lab perpetual license:

Serial number: 501606204774

Licensed to: Clinical Epidemiology and Clinical Statistic Center
Faculty of Medicine, Chiang Mai University

Notes:

1. Unicode is supported; see [help unicode_advice](#).
2. More than 2 billion observations are allowed; see [help obs_advice](#).
3. Maximum number of variables is set to 5000; see [help set_maxvar](#).

Command

Variables

Filter variables here

Name Label

There are no items to show.


Properties

Variables

Name	
Label	
Type	
Format	
Value label	
Notes	

Data

Frame	default
Filename	
Label	
Notes	
Variables	0
Observations	0



นำเข้าไฟล์ xls/cvs

Stata/MP 16.0

FileEditDataGraphicsStatisticsUserWindowHelp

Open...Ctrl+O

SaveCtrl+S

Save as...Ctrl+Shift+S

View...

Do...

Filename...

Change working directory...

Log

Import

Export

Print

Example datasets...

Recent files

Exit

Excel spreadsheet (*.xls;*.xlsx)

Text data (delimited, *.csv, ...)

SPSS data (*.sav)

SAS data (*.sas7bdat)

Text data in fixed format

Text data in fixed format with a dictionary

Unformatted text data

SAS XPORT Version 8 (*.v8xpt)

SAS XPORT Version 5 (*.xpt)

Federal Reserve Economic Data (FRED)

Haver Analytics database

ODBC data source

dBase (*.dbf)

Statistics/Data Analysis

MP - Parallel Edition

(R)

16.0

Copyright 1985-2019 StataCorp LLC

StataCorp

4905 Lakeway Drive

College Station, Texas 77845 USA

800-STATA-PC

979-696-4600

979-696-4601 (fax)

<http://www.stata.com>

stata@stata.com

ense:

logy and Clinical Statistic Center

ne, Chiang Mai University

[unicode advice.](#)

is are allowed; see [help obs advice.](#)

set to 5000; see [help set maxvar.](#)

Variables

Filter variables here

Name	Label
There are no items to show.	

Properties

Variables

Name	
Label	
Type	
Format	
Value label	
Notes	

Data

Frame	default
Filename	
Label	
Notes	
Variables	0
Observations	0

C:\Program Files\Stata16

CAP NUM OVR

30°C

มีแดดส่วนใหญ่

8:55

2/3/2565

Stata/MP 16.0

FileEditDataGraphicsStatisticsUserWindowHelp

History

Filter commands here

#	Command	_rc
1	import excel "C:\Users\Tha...	
2	clear	
3	import delimited "C:\Users\...	

MP - Parallel Edition

4905 Lakeway Drive
College Station, Texas 77845 USA
800-STATA-PC <http://www.stata.com>
979-696-4600 stata@stata.com
979-696-4601 (fax)

30-student 2-core Stata lab perpetual license:
Serial number: 501606204774
Licensed to: Clinical Epidemiology and Clinical Statistic Center
Faculty of Medicine, Chiang Mai University

Notes:
1. Unicode is supported; see [help unicode advice](#).
2. More than 2 billion observations are allowed; see [help obs advice](#).
3. Maximum number of variables is set to 5000; see [help set maxvar](#).

```
. import excel "C:\Users\Thananan\Downloads\HBS.xlsx", sheet("HBS") firstrow  
(215 vars, 207,191 obs)  
  
. clear  
  
. import delimited "C:\Users\Thananan\Desktop\Tobacco Project\Health Sit\Microdata HBS 2564\Microdata HBS 2564.csv", encoding(UTF-8)  
(215 vars, 207,191 obs)  
  
. 
```

Command

Variables

Filter variables here

Name	Label
reg	REG
cwt	CWT
area	AREA
month_	MONTH_
yr	YR
hh_no	HH_NO
type	TYPE
member	MEMBER
listing	LISTING
enum	ENUM
hl1	HL1
hl3	HL3
hl4	HL4

Properties

Variables

Name	Label
Type	
Format	
Value label	
Notes	

Data

Frame	default
Filename	
Label	
Notes	
Variables	215
Observations	207,191

C:\Program Files\Stata16

30°C
มีแดดส่วนใหญ่

Stata

9:09
2/3/2565



ปรับแต่งหน้าต่าง **Stata** เพิ่มสีสันก่อนเริ่มใช้
งาน

Stata/MP 16.0

FileEditDataGraphicsStatisticsUserWindowHelp

History

Filter commands here

#Command_rc

There are no items to show.

STATA (R)

Statistics/Data Analysis

MP - Parallel Edition

16.0

Copyright 1985-2019 StataCorp LLC
StataCorp
4905 Lakeway Drive
College Station, Texas 77845 USA
800-STATA-PC <http://www.stata.com>
979-696-4600 stata@stata.com
979-696-4601 (fax)

30-student 2-core Stata lab perpetual license:
Serial number: 501606204774
Licensed to: Clinical Epidemiology and Clinical Statistic Center
Faculty of Medicine, Chiang Mai University

Notes:
1. Unicode is supported; see [help unicode_advice](#).
2. More than 2 billion observations are allowed; see [help obs_advice](#).
3. Maximum number of variables is set to 5000; see [help set_maxvar](#).

http://www.stata.com

Command

Variables

Filter variables here

Name	Label
There are no items to show.	

Properties

Variables

Name	
Label	
Type	
Format	
Value label	
Notes	

Data

Frame	default
Filename	
Label	
Notes	
Variables	0
Observations	0

30°C

มีแดดส่วนใหญ่

8:52

2/3/2565

Stata/MP 16.0

FileEditDataGraphicsStatisticsUserWindowHelp

History

Filter commands here

#Command_rc

There are no items to show.

Statistics/Data Analysis

MP - Parallel Edition

30-student 2-core Stata lab
Serial number: 501600
Licensed to: Clinica
Facult

Notes:
1. Unicode is supporte
2. More than 2 billion
3. Maximum number of

Command

Variables

Filter variables here

Name	Label
There are no items to show.	

Properties

Variables

Name	Label
Type	
Format	
Value label	
Notes	

Data

Frame	default
Filename	
Label	
Notes	
Variables	0
Observations	0

General preferences

General

Results

Viewer

Data Editor

Internet

Colors

Color scheme:
Custom 2

Results

Standard

Error

Input

Link

Hilite

Background

☐ Bold

☐ Bold

☐ Bold

☒ Bold

☐ Bold

☒ Bold

☐ Bold

☐ Underline

☒ Underline

☐ Underline

Behavior

1Line gap

200Scrollback buffer size in kilobytes (takes effect after restart)

OK

Cancel

Apply

C:\Program Files\Stata16

30°C
มีแดดส่วนใหญ่

8:53
2/3/2565

CAPNUMOVR



Data management

Type of data (1)

14



NOMINAL DATA

- ▶ values that the data may have do **not have specific order**
- ▶ values **act as labels** with **no real meaning**
- ▶ categories, states
- ▶ Binomial: two possible values
- ▶ Multinomial: more than two possible values

e.g. Health status healthy =1 sick=2

e.g. Treatment new regimen = 1 standard regimen = 2

e.g. hair color brown =1 blond =2 black =100

ORDINAL DATA

- ▶ values with **some kind of ordering**
- ▶ data that has been measured or counted

e.g. social class: upper=1 middle = 2 working = 3

e.g. glioblastoma tumor grade: 1 2 3 4 5

e.g. position in a race: 1st 2nd 3rd

Type of data (3)

15



DISCRETE

- ▶ distinct or separate parts, with **no finite detail**
e.g. children in family

CONTINUOUS

- ▶ between any two values, there would be a third
e.g. between meters there are centimeters

INTERVAL

- ▶ **equal intervals** between values and **an arbitrary zero** on the scale
e.g. temperature gradient

RATIO

- ▶ **equal intervals** between values and an **absolute zero**
e.g. weight, body mass index


16

Cat. 1 2 99

Cont. 99

ト

17



Data Editor (Edit) - (Unsaved)

FileEditViewDataTools






reg[1]

	reg	cat	area	month	yr	h1_yr	type	member	listing	enum	N11	N15	sex	age	N16	N17	N18	N19	N110	N111	N112	N113	
1	1	10	1	2	01	9	1	1	1	11	1	1	2	10	1	2	4	1012	10001	2	-	10000	
2	1	10	1	2	04	0	1	1	2	11	1	1	1	13	1	5	1	1011	10400	0	-	10000	
3	1	10	1	2	04	7	1	1	2	11	1	1	1	10	1	0	1	0000	-	-	-	10000	
4	1	10	1	2	04	7	1	1	2	11	2	0	2	02	1	0	2	0000	-	-	1	0	
5	1	10	1	2	04	0	1	-	5	14	-	-	-	-	-	-	-	-	-	-	-	0	
6	1	10	1	2	04	0	1	1	1	11	1	1	1	06	1	0	1	0000	-	-	7	10000	
7	1	10	1	2	04	9	1	1	1	11	2	0	2	07	1	1	1	0000	-	-	-	4	
8	1	10	1	2	04	10	1	1	1	11	1	1	1	08	1	0	1	1011	10101	0	-	10000	
9	1	10	1	2	04	10	1	1	1	11	2	0	2	09	1	1	1	0000	-	-	1	10000	
10	1	10	1	2	04	10	1	1	1	11	2	0	2	10	1	2	-	-	-	-	-	-	
11	1	10	1	2	04	11	1	1	1	11	1	1	1	11	1	0	1	0000	-	-	7	10000	
12	1	10	1	2	04	12	1	1	1	11	1	1	1	12	1	0	1	0000	-	-	-	10000	
13	1	10	1	2	04	12	1	1	1	11	1	1	1	13	1	0	2	1010	10104	2	-	10000	
14	1	10	1	2	04	13	1	1	1	11	2	0	2	14	1	0	2	1011	10104	3	-	10000	
15	1	10	1	2	04	14	1	1	1	11	0	10	2	15	1	0	1	0000	-	-	4	10000	
16	1	10	1	2	04	14	1	-	2	12	-	-	-	-	-	-	-	-	-	-	-	-	
17	1	10	1	2	04	15	1	1	1	11	1	1	1	16	1	2	4	1011	10101	0	-	10000	
18	1	10	1	2	04	15	1	1	0	11	2	13	2	17	1	1	4	0000	-	-	1	10000	
19	1	10	1	2	04	15	1	1	2	11	2	14	1	1	2	-	-	-	-	-	-	-	
20	1	10	1	2	04	16	1	1	1	11	1	1	1	18	1	4	1	0000	-	-	7	10000	
21	1	10	1	2	04	16	1	1	0	11	2	13	2	19	1	0	1	0000	-	-	1	10000	
22	1	10	1	2	04	16	1	1	2	11	2	14	1	2	2	-	-	-	-	-	7	10000	
23	1	10	1	1	04	1	1	1	1	11	1	1	1	20	1	1	2	0000	-	-	4	10000	
24	1	10	1	1	04	2	1	1	1	11	2	0	2	21	1	0	2	1011	10111	0	-	10000	
25	1	10	1	1	04	2	1	1	1	11	1	1	1	22	1	0	2	1011	10111	0	-	10000	
26	1	10	1	1	04	3	1	1	1	11	2	0	2	23	1	1	1	0000	-	-	1	10000	
27	1	10	1	1	04	3	1	1	1	11	1	1	1	24	1	1	1	0000	-	-	2	10000	
28	1	10	1	1	04	4	1	1	1	11	1	1	1	25	1	1	5	1012	00000	0	-	10000	
29	1	10	1	1	04	5	1	1	1	11	1	1	1	26	1	1	9	2	1012	00001	0	-	10000
30	1	10	1	1	04	5	1	1	1	11	1	1	1	27	1	1	9	2	1012	00001	0	-	10000
31	1	10	1	1	04	6	1	1	1	11	1	1	1	28	1	1	9	2	1012	10001	0	-	10000
32	1	10	1	1	04	7	1	1	2	11	1	1	2	29	1	1	9	1	1011	00000	0	-	10000
33	1	10	1	1	04	7	1	1	1	11	2	13	2	30	1	1	1	0000	-	-	2	10000	
34	1	10	1	1	04	8	1	1	1	11	1	1	1	31	1	1	1	1011	10001	0	-	10000	
35	1	10	1	1	04	9	1	1	1	11	1	1	1	32	1	1	1	1011	10001	0	-	10000	
36	1	10	1	1	04	10	1	1	1	11	1	1	1	33	1	1	1	1011	10001	0	-	10000	
37	1	10	1	1	04	11	1	1	1	11	1	1	1	34	1	1	1	1011	10001	0	-	10000	
38	1	10	1	1	04	12	1	1	1	11	1	1	1	35	1	1	1	1011	10001	0	-	10000	
39	1	10	1	1	04	13	1	1	1	11	1	1	1	36	1	1	1	1011	10001	0	-	10000	
40	1	10	1	1	04	14	1	1	1	11	1	1	1	37	1	1	1	1011	10001	0	-	10000	
41	1	10	1	1	04	15	1	1	1	11	1	1	1	38	1	1	1	1011	10001	0	-	10000	
42	1	10	1	1	04	16	1	1	1	11	1	1	1	39	1	1	1	1011	10001	0	-	10000	
43	1	10	1	1	04	17	1	1	1	11	1	1	1	40	1	1	1	1011	10001	0	-	10000	
44	1	10	1	1	04	18	1	1	1	11	1	1	1	41	1	1	1	1011	10001	0	-	10000	
45	1	10	1	1	04	19	1	1	1	11	1	1	1	42	1	1	1	1011	10001	0	-	10000	
46	1	10	1	1	04	20	1	1	1	11	1	1	1	43	1	1	1	1011	10001	0	-	10000	
47	1	10	1	1	04	21	1	1	1	11	1	1	1	44	1	1	1	1011	10001	0	-	10000	
48	1	10	1	1	04	22	1	1	1	11	1	1	1	45	1	1	1	1011	10001	0	-	10000	
49	1	10	1	1	04	23	1	1	1	11	1	1	1	46	1	1	1	1011	10001	0	-	10000	
50	1	10	1	1	04	24	1	1	1	11	1	1	1	47	1	1	1	1011	10001	0	-	10000	
51	1	10	1	1	04	25	1	1	1	11	1	1	1	48	1	1	1	1011	10001	0	-	10000	
52	1	10	1	1	04	26	1	1	1	11	1	1	1	49	1	1	1	1011	10001	0	-	10000	
53	1	10	1	1	04	27	1	1	1	11	1	1	1	50	1	1	1	1011	10001	0	-	10000	
54	1	10	1	1	04	28	1	1	1	11	1	1	1	51	1	1	1	1011	10001	0	-	10000	
55	1	10	1	1	04	29	1	1	1	11	1	1	1	52	1	1	1	1011	10001	0	-	10000	
56	1	10	1	1	04	30	1	1	1	11	1	1	1	53	1	1	1	1011	10001	0	-	10000	
57	1	10	1	1	04	31	1	1	1	11	1	1	1	54	1	1	1	1011	10001	0	-	10000	
58	1	10	1	1	04	32	1	1	1	11	1	1	1	55	1	1	1	1011	10001	0	-	10000	
59	1	10	1	1	04	33	1	1	1	11	1	1	1	56	1	1	1	1011	10001	0	-	10000	
60	1	10	1	1	04	34	1	1	1	11	1	1	1	57	1	1	1	1011	10001	0	-	10000	
61	1	10	1	1	04	35	1	1	1	11	1	1	1	58	1	1	1	1011	10001	0	-	10000	
62	1	10	1	1	04	36	1	1	1	11	1	1	1	59	1	1	1	1011	10001	0	-	10000	
63	1	10	1	1	04	37	1	1	1	11	1	1	1	60	1	1	1	1011	10001	0	-	10000	
64	1	10	1	1	04	38	1	1	1	11	1	1	1	61	1	1	1	1011	10001	0	-	10000	
65	1	10	1	1	04	39	1	1	1	11	1	1	1	62	1	1	1	1011	10001	0	-	10000	
66	1	10	1	1	04	40	1	1	1	11	1	1	1	63	1	1	1	1011	10001	0	-	10000	
67	1	10	1	1	04	41	1	1	1	11	1	1	1	64	1	1	1	1011	10001	0	-	10000	
68	1	10	1	1	04	42	1	1	1	11	1	1	1	65	1	1	1	1011	10001	0	-	10000	
69	1	10	1	1	04	43	1	1	1	11	1	1	1	66	1	1	1	1011	10001	0	-	10000	
70	1	10	1	1	04	44	1	1	1	11	1	1	1	67	1	1	1	1011	10001	0	-	10000	
71	1	10	1	1	04	45	1	1	1	11	1	1	1	68	1	1	1	1011	10001	0	-	10000	
72	1	10	1	1	04	46	1	1	1	11	1	1	1	69	1	1	1	1011	10001	0	-	10000	
73	1	10	1	1	04	47	1	1	1	11	1	1	1	70	1	1	1	1011	10001	0	-	10000	
74	1	10	1	1	04	48	1	1	1	11	1	1	1	71	1	1	1	1011	10001	0	-	10000	
75	1	10	1	1	04	49	1	1	1	11	1	1	1	72	1	1	1	1011	10001	0	-	10000	
76	1	10	1	1	04	50	1	1	1	11	1	1	1	73	1	1	1	1011	10001	0	-	10000	
77	1	10	1	1	04	51	1	1	1	11	1	1	1	74	1	1	1	1011	10001	0	-	10000	
78	1	10	1	1	04	52	1																

- Str2 = red / byte = black



Save command in Stata

18



Rename variable / deststring

19



```
. label variable hl4 "sex"

. rename hl4 sex
```

Destring data from string to numeric

20

The screenshot shows the Stata software interface. The 'Data' menu is open, and the path 'Other variable-transformation commands' > 'Convert variables from string to numeric' is highlighted. The command log on the left shows the following commands:

```
1 import excel
2 clear
3 import del
4 label variable
5 rename hl
6 destring sex
7 rename hl
8 destring age
9 gen agegr
10 drop agegr
11 do "C:\Users\marion\Documents\stata\stata.dta"
12 frame create agegroup
13 frame change agegroup
14 frame change default
15 label define agegroup 1 "0-15"
16 label define agegroup 1 "0-15"
17 label values agegr agegroup
18 label values agegr .
19 tab agegr
20 label values agegr agegroup
21 tab agegr
22 gen ht = nd1
23 help ds
24 destring
```

The command log also shows the output of the 'tab agegr' command:

RECODE of age (HL5)	Freq.	Percent	Cum.
0-15	34,590	17.57	17.57
16-30	29,641	15.06	32.63
31-45	38,118	19.36	51.99
46-60	49,933	25.37	77.36
>60	44,563	22.64	100.00
Total	196,845	100.00	

The dialog box titled 'destring - Convert string variables to numeric variables' has the following options:



- String variables to convert: (leave empty for all variables)
- ☐ Create new numeric variables named:
- ☒ Convert specified variables to numeric (original strings will be lost)
- Options:
 - ☐ Remove these characters:
 - ☐ Also remove all illegal Unicode characters
 - ☐ Treat characters as byte sequence
 - ☐ Convert nonnumeric strings to missing values
 - ☐ Generate numeric variables as type float
 - ☐ Convert percent variables to fractional form
 - ☐ Treat commas as decimals

Buttons at the bottom: ? C [icon] OK Cancel Submit

```
. destring sex, replace
sex: all characters numeric; replaced as byte
(10346 missing values generated)
```


Generate new variable

21




```
. recode age min/15=1 16/30=2 31/45=3 46/60=4 61/max=5, gen (agegr)  
(195350 differences between age and agegr)
```

```
. gen agegr = .
```

Label data in variable (1)

22



The screenshot shows the Stata Variables Manager dialog box. The main table lists variables with columns: #, Name, Label, Type, Format, Value label, and Notes. The variable 'agegr' is selected at the bottom. The 'Variable properties' panel on the right shows details for 'agegr'.

#	Name	Label	Type	Format	Value label	Notes
1	hc9	HC9	str1	%9s		
2	hc10	HC10	str1	%9s		
3	hc11	HC11	str1	%9s		
4	hc12	HC12	str1	%9s		
5	hc13	HC13	str1	%9s		
6	hc14	HC14	str1	%9s		
7	hc15	HC15	str1	%9s		
8	hc16	HC16	str1	%9s		
9	pop_weight	POP_WEIGHT	float	%9.0g		
10	hh_weight	HH_WEIGHT	float	%9.0g		
11	occ	OCC	str2	%9s		
12	indust	INDUST	str2	%9s		
13	new_hh_n	NEW_HH_N	long	%8.0g		
14	agegr	RECODE of age (HL5)	int	%9.0g		

Variable properties

Name: agegr

Label: RECODE of age (HL5)

Type: int

Format: %9.0g [Create...]

Value label: [Manage...]



Notes: No notes [Manage...]

< > Reset Apply

Vars: 216 CAP NUM

Label data in variable (2)

23



Label data in variable (3)

24

Variables Manager

Filter variables here

Drag a column header here to group by that column.

#	Name	Label	Type	Format	Value label	Notes
hc9	HC9	HC9	str1	%9s		
hc10	HC10	HC10	str1	%9s		
hc11	HC11	HC11	str1	%9s		
hc12	HC12	HC12	str1	%9s		
hc13	HC13	HC13	str1	%9s		
hc14	HC14	HC14	str1	%9s		
hc15	HC15	HC15	str1	%9s		
hc16	HC16	HC16	str1	%9s		
pop_weight	POP_WEIGHT	POP_WEIGHT	float	%9.0g		
hh_weight	HH_WEIGHT	HH_WEIGHT	float	%9.0g		
occ	OCC	OCC	str2	%9s		
indust	INDUST	INDUST	str2	%9s		
new_hh_n	NEW_HH_N	NEW_HH_N	long	%8.0g		
agegr	RECODE of age (HL5)	RECODE of age (HL5)	int	%9.0g	agegroup	

Variable properties

Name: agegr

Label: RECODE of age (HL5)

Type: int

Format: %9.0g Create...

Value label: agegroup Manage...

Notes: No notes Manage...

< > Reset Apply

Ready Vars: 216 CAP NUM

Label data in variable (3)

25

```
. tab agegr
```

RECODE of age (HL5)	Freq.	Percent	Cum.
1	34,590	17.57	17.57
2	29,641	15.06	32.63
3	38,118	19.36	51.99
4	49,933	25.37	77.36
5	44,563	22.64	100.00
Total	196,845	100.00	

```
. label values agegr agegroup
```

```
. tab agegr
```

RECODE of age (HL5)	Freq.	Percent	Cum.
0-15	34,590	17.57	17.57
16-30	29,641	15.06	32.63
31-45	38,118	19.36	51.99
46-60	49,933	25.37	77.36
>60	44,563	22.64	100.00
Total	196,845	100.00	

Label data in variable (4)

26

```
. tab sex
```

sex	Freq.	Percent	Cum.
1	92,869	47.18	47.18
2	103,976	52.82	100.00
Total	196,845	100.00	

```
. label define sex 1 "male" 2 "female", replace
```


```
. label values sex sex
```

```
. tab sex
```

sex	Freq.	Percent	Cum.
male	92,869	47.18	47.18
female	103,976	52.82	100.00
Total	196,845	100.00	

การลบตัวแปร

27



- ▶ คลิกขวาที่ชื่อตัวแปร แล้วกด drop
- ▶ พิมพ์โค้ด drop ตามด้วยชื่อตัวแปร

พุดจาภาษา stata (1)

28

- ▶ **Gen** มาจาก **generate** หมายถึง สร้างตัวแปรใหม่
- ▶ **Replace** หมายถึง แทนที่
- ▶ **Recode** หมายถึง แทนค่า
- ▶ **If** หมายถึง ถ้า โดย = ที่มาหลัง if ต้องเป็น ==
- ▶ **&** หมายถึง และ
- ▶ **|** (อยู่ตรง ข.ไข) หมายถึง หรือ
- ▶ **.** **""** หมายถึง ค่าว่าง
- ▶ **!=** หมายถึง ไม่เท่ากับ
- ▶ **+ - * / ^** บวก ลบ คูณ หาร ยกกำลัง
- ▶ **Clear** หมายถึง ล้างข้อมูลทั้งหมด
- ▶ **Use** หมายถึง ใช้ข้อมูลหรือเปิดข้อมูล
- ▶ **Disp** หรือ **display** แปลว่า แสดงผล
- ▶ **Tab** หรือ **tabulate** หมายถึง ตาราง

Ex. Gen bmi = weight/(height^2)

สร้างตัวแปรชื่อ bmi เท่ากับ

ค่าในตัวแปรชื่อ weight หาร (ค่าในตัวแปรชื่อ height ยกกำลัง 2)

Ex. Gen diff = pre-post if age !=. & (pre-post)>0

สร้างตัวแปรชื่อ diff เท่ากับ ค่าในตัวแปรชื่อ pre ลบด้วย ค่าในตัวแปรชื่อ post เมื่อ age ไม่เท่ากับค่าว่าง และ ค่าใน pre ลบด้วย post มากกว่า 0

Ex. Replace age = . If age == 999 | age > 100

แทนที่ ตัวแปรชื่อ age ให้เท่ากับค่าว่าง ถ้า ตัวแปรชื่อ age เท่ากับ 999 หรือมากกว่า 100

Ex. Recode age min/20=1 21/60=2 61/max=3, gen (agegr)
แปลงค่า age คำน้อยสุดถึง20เท่ากับ 1 ค่า21ถึง60เท่ากับ 2 ค่า61ถึงสูงสุดเท่ากับ 3

สร้างเป็นตัวแปรชื่อ agegr

Ex. Disp 52/5*100 แสดงผล 52 หารด้วย 5 คูณ 100

Ex. Tab var1 var2


สร้างตาราง var1 เป็น row และ var2 เป็น

Terminology


29

- ▶ Constants ค่าคงที่
- ▶ **Variable** ตัวแปร
- ▶ **Independent** ตัวแปรตาม
- ▶ **Dependent** ตัวแปรต้น
- ▶ Extraneous ตัวแปรภายนอก
- ▶ **Confounding**
 - ▶ มีความสัมพันธ์กับทั้ง predictive และ outcome variable โดยต้องเป็น cause of outcome แต่ไม่ได้มี predictor เป็น cause (ไม่ได้เป็น intermediate) หลังจาก adjust ต่างจาก crude
- ▶ **Effect modifier/Interaction**
 - ▶ ทำให้ ความสัมพันธ์ ระหว่าง predictor กับ outcome เสีย homogeneity
 - ▶ stratified specific risk ratio แตกต่างกัน

Effect modification



Confounding





Study Design

Type of study

31

► Observational

► Descriptive (Parameter Estimation)


- Cross-sectional

► Analytic (Hypothesis testing)

- Cross-sectional
- Case-control
- Cohort

► Experimental

- True experimental >> RCT, non-RCT
- Quasi experimental



Observational study

32

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

Cohort

Exposure $\square$ Outcome บังคับไปหาผลลัพธ์
บอก causality ได้ ศึกษาได้ทั้งไปข้างหน้าและ
ย้อนหลัง
ใช้ศึกษากับ outcome ที่เป็น incidence
เริ่มศึกษาจากตอนที่ยังไม่เริ่มป่วย

Smoking (y/n) $\square$ Cancer (y/n)
Diabetes(y/n) $\square$ Chronic kidney
disease

Case-Control

Outcome $\square$ Exposure
บอก causality ได้
ใช้ศึกษากับ outcome ที่เป็น prevalence

Cancer (y/n) $\square$ Smoking (y/n)
Stroke after surgery(y/n) $\square$ surgery
time

Cross-sectional

Exposure $\leftrightarrow$ Outcome
บอกได้แค่สัมพันธ์กันหรือไม่ บอกค่าเป็น
เหตุผลไม่ได้

Smoking (y/n) $\leftrightarrow$ Cancer (y/n)
Depress $\leftrightarrow$ Quality of life

Cross-sectional

33

- Relationship of Exposure $\leftrightarrow$ Outcome
- Prevalence Odds ratio

Population
at risk

Sampling

Representative
sample

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

Cross-sectional

34


- ▶ Single point in time (**Snapshot**) -> Exposure and Outcome
- ▶ **measured at one point** in time or over a period
- ▶ **No Follow up**
- ▶ **ทำง่าย ใช้เวลาน้อย**
- ▶ **ข้อมูล Individual**
- ▶ Measure of frequency : **Prevalence**
- ▶ Measure of association: **Prevalence ratio (PR), Prevalence Odds ratio(POR)**
- ▶ ใช้กับ โรคที่ไม่ทราบ onset ex. โรคเรื้อรัง
- ▶ ได้ข้อมูล POR <- Overestimate risk มากกว่า PR
- ▶ No Temporal sequence **บอกได้แค่ว่ามีAssociation ไม่ได้บอกว่าอะไรเป็นสาเหตุ**
- ▶ ใช้กับRare exposure หรือ Rare outcome ยาก
- ▶ **Prevalence-incidence bias** (Length Bias / Survival bias)-> เจอโรคที่มี long duration ได้มากกว่า

Case-control

35

- causality
- Outcome □ Exposure
- Odds ratio

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D



Target population
V
Source population
V
Eligible
population(Characteristics)
V
Study Participants

Case-control

36



- ▶ Pro
 - ▶ เลือกMultiple Exposureได้
 - ▶ ไข้กับRare Diseaseได้
 - ▶ ไม่มี fellow up
- ▶ Cons
 - ▶ บอก Casual Temporalityได้
 - ▶ Uncertain temporal sequence (ถ้ามี Information bias)
- ▶ Measure of frequency: **Prevalence**
- ▶ Measure of association: **Odds Ratio**
- ▶ Bias ที่เกิดขึ้นบ่อย
 - ▶ Selection bias
 - ▶ Participants not represent Population
 - ▶ Information bias
 - ▶ Memory bias -> Can't remember -> Misclassification exposure
 - ▶ Recall bias -> Case try to recall more than control ต้องมีcomparison group
ex. แม่มีลูกเป็นโรคจะrecallมากกว่าแม่มีลูกปกติ
 - ▶ Interview bias -> ex. Review caseมากกว่าControl


Cohort

- causality
- Exposure $\square$ outcome
- Relative risk ratio

Prospective time sequence

Retrospective time sequence

37



Cohort

38

- ▶ Disease-free Population follow up over time
- ▶ ติดตามได้ Incident (New case) / AR
- ▶ Exposure -> Follow -> Outcome
 - ▶ Fixed Exposure (ex Blood group),
 - ▶ Time-dependent Exposure (ex Blood Sugar)
 - ▶ Hard Outcome ex. Death , Disease
 - ▶ Intermediate Outcome ex. CD4
- ▶ Comparison group ต้องมี as similar as possible
- ▶ ดีสุดต้อง Internal Comparison (เปรียบเทียบในCohortเดียวกัน) แต่ถ้าไม่ได้ก็ใช้ Comparison Group (External Comparison)
- ▶ Pro
 - ▶ ใช้กับRare Exposure, multiple outcome,
 - ▶ บอก temporal sequenceได้(Exposureเกิดก่อนOutcome)
 - ▶ บอกCause -> Effect Relation (Temporality) ได้ดีกว่า Case-Control
- ▶ Con
 - ▶ แพง ใช้เวลามาก
 - ▶ Loss Follow up
- ▶ Measure of frequency : **Incidence**
- ▶ Measurements Association : **Relative Risk**





Types of statistic

Types of statistic


By Level of Generalization

- ▶ Descriptive Statistics
- ▶ Inferential Statistics
 - Parameter Estimation
 - Hypothesis Testing
 - Comparison
 - Association
 - Multivariable data analysis
 - Multivariate data analysis




Epidemiological study design

41



Epidemiological study design

42



Descriptive study

43


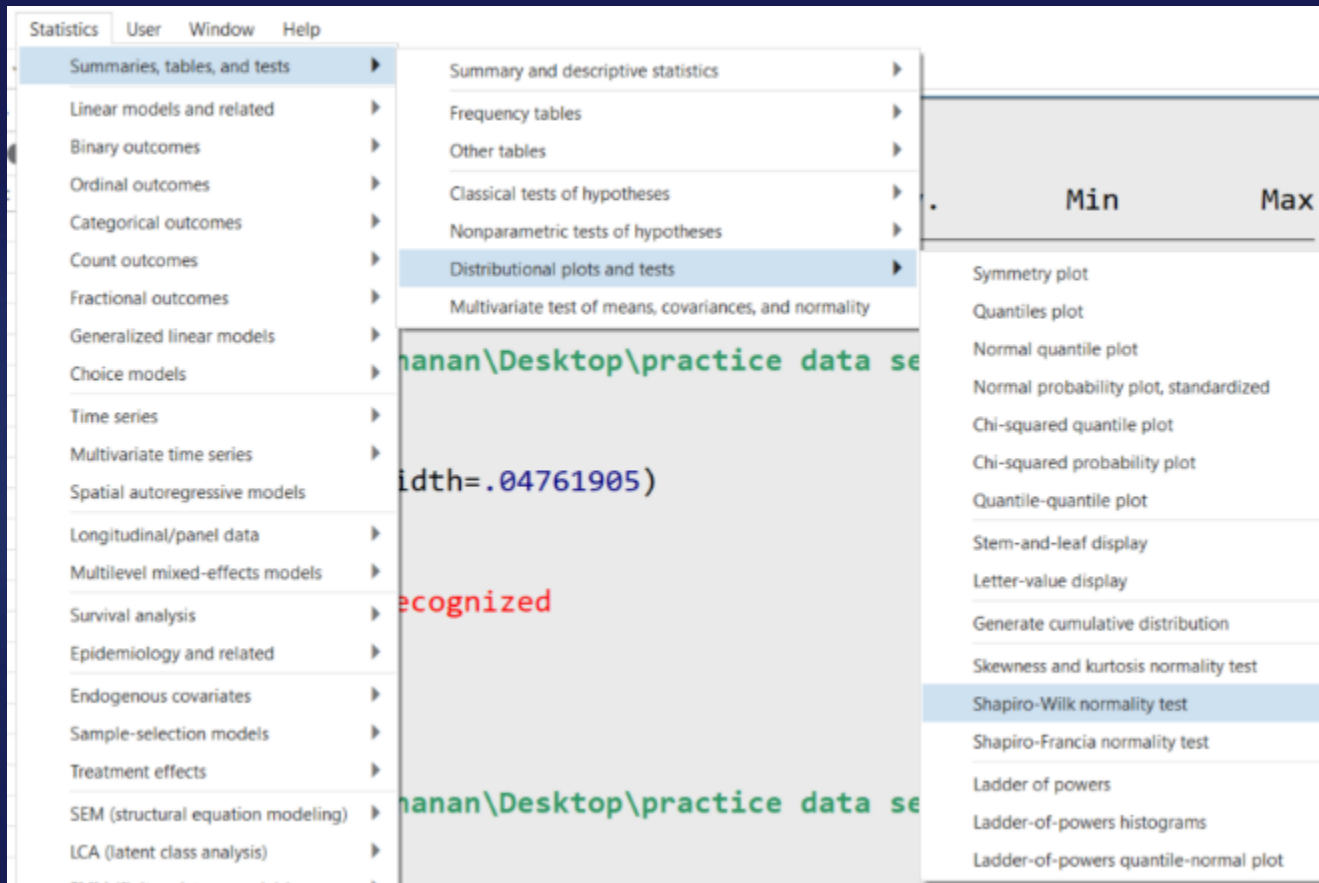


Describe sample statistics

- ▶ **Categorical** Variables
 - Ratio, Proportion, Percent (%)
- ▶ **Continuous** Variable
 - **Normal** Distribution
 - Mean, SD
 - **Not normal** Distribution
 - Median, Range/IQR

Normal distribution testing : Shapiro-Wilk test

44



```
. swilk scr_inc1age
```



Shapiro-Wilk W test for normal data					
Variable	Obs	W	V	z	Prob>z
scr_inc1age	480	0.98312	5.475	4.079	0.00002

If P-value > 0.05 แปลว่า เป็น normal distribution

Normal distribution testing :

Histogram



45



ไม่ใช่โค้งปกติ เบ๊ขว

Continuous Variable

46



```
. sum scr_inc1age, detail
```

Derived age		
Percentiles		Smallest
1%	18	18
5%	18	18
10%	19	18
25%	21	18
50%	23	
75%	26	
90%	29	30
95%	29	30
99%	30	30

Largest	
Obs	480
Sum of Wgt.	480
Mean	23.57708
Std. Dev.	3.399358
Variance	11.55563
Skewness	.1815262
Kurtosis	1.99793

ไม่ใช่ normal distribution

- Median = 23
- Q1 = 21
- Q3 = 26
- IQR = Q3 - Q1 = 5

Normal distribution

- Mean = 23.58
- S.D. = 3.40

Measures in epidemiology

การวัดทางระบาดวิทยา

Aims of **Epidemiologic** Research

48

1. **Describe** → Measure of **Frequency**
 - a. How common of CHD among adults in Province A?
 - b. What is the frequency of CHD among males and females?
2. **Explain** → Measure of **Association**
 - a. Why men are more likely than women to develop CHD?
 - b. Does smoking increase the risk of CHD?
3. **Predict** → Measure of **Impact**
 - a. How many CHD cases would occur if we provided a specific intervention?
 - b. How many new CHD cases will occur in province A next year?
4. What could be done to **prevent** new cases? And how?

Measures of frequency

การวัดความถี่/การกระจาย

Measure of FREQUENCY

50



▶ Ratio

- ▶ relative magnitude of two quantities or a **comparison of any two values**
- ▶ The numerator and denominator need **not be related**
- ▶ **$=A/B$**

▶ Proportion



- ▶ the **comparison of a part to the whole**
- ▶ It is a type of ratio in which the **numerator is included in the denominator**
- ▶ **$=A/(A+B)$**

▶ Rate

- ▶ Measure an event occurs in a defined population **over a specified period of time**
- ▶ **$= A/\text{time}$**

Proportion สัดส่วน ตัวตั้ง เป็น ส่วนหนึ่งของ ตัวหาร

51



```
. tab sex
```

sex	Freq.	Percent	Cum.
male	92,869	47.18	47.18
female	103,976	52.82	100.00
Total	196,845	100.00	

Ratio อัตราส่วน ตัวตั้ง ไม่ใช่ ส่วนหนึ่ง ของตัวหาร

52

sex	Freq.	Percent	Cum.
male	92,869	47.18	47.18
female	103,976	52.82	100.00
Total	196,845	100.00	

```
. display 103976/92869  
1.1195986
```

Female : Male = 1.12 : 1

Rate, Ratio or Proportion ?

53

Indicator	ตัวตั้ง Numerator	ตัวหาร Denominator	Rate/Ratio/Proportion
General fertility rate อัตราเจริญพันธุ์ทั่วไป	จำนวนเด็กเกิดมีชีวิตทั้งหมด	จำนวนผู้หญิงอายุ 15-49 ปี	Ratio
Infant mortality rate	จำนวนทารกที่ตายในขวบปีแรก	จำนวนเด็กเกิดมีชีวิตทั้งหมดในปีนั้น	Proportion
Case-fatality rate อัตราป่วยตาย	จำนวนผู้ป่วยที่เสียชีวิต	จำนวนผู้ป่วยทั้งหมดในช่วงเวลานั้น	Proportion
Mortality rate อัตราตาย	จำนวนผู้เสียชีวิตในช่วงเวลานั้น	จำนวนประชากรทั้งหมดในช่วงเวลานั้น	Proportion
Attack rate อัตราป่วย	จำนวนผู้ป่วยใหม่ในช่วงเวลานั้น	จำนวนประชากรทั้งหมดในตอนจะเริ่มทำการศึกษา	



Prevalence

Prevalence (1) ความชุก

55

- ▶ **Measure existing** or presenting of “states” **at a specified time**
- **Count both new and old cases**

$$\frac{\text{จำนวนผู้ป่วยทั้งหมด ทั้งเก่าและใหม่ ณ ช่วงเวลานั้น}}{\text{จำนวนประชากรทั้งหมด ณ ช่วงเวลานั้น}}$$

1. **Point Prevalence**
2. **Period prevalence**

Prevalence (2)

56



Point prevalence ; at time ณเวลาจุดใดจุดหนึ่ง

$$\frac{\text{จำนวนผู้ป่วยทั้งหมดทั้งเก่าและใหม่ในกลุ่มประชากรนั้น}}{\text{จำนวนประชากร ณ เวลาที่กำหนด}}$$


Example: วันที่ 1 มกราคม 2565 บริษัท ก มีพนักงาน 5,000 คน และมี 100 คนป่วยเป็นเบาหวาน

จงหาความชุกของโรคเบาหวานในบริษัท ก ณวันที่ 1 มกราคม 2565

- $= 100/5000 = 0.02 = 2 \text{ per } 100 = 2\%$

Point Prevalence

57



$$= 4/8 = 0.5 = 50\%$$

Prevalence (3)

58



Period prevalence ; during interval ในช่วงเวลาที่กำหนด

$$\frac{\text{จำนวนผู้ป่วยทั้งหมดที่ปรากฏในช่วงระยะเวลาที่กำหนด}}{\text{ค่าเฉลี่ยของจำนวนประชากรในช่วงระยะเวลาที่กำหนด}}$$



Example: ในปี 2564 บริษัท ก มีพนักงาน 5000 คน ในเดือนมกราคม และ 4900 คน ในเดือนธันวาคม มีพนักงานที่ได้รับการวินิจฉัยว่าเป็นโรคมะเร็งก่อนวันที่ 1 มกราคม 2564 จำนวน 100 คน และมีผู้ที่ได้รับการวินิจฉัยว่าเป็นโรคมะเร็งในปี 2564 อีก 5 คน ในจำนวนผู้ป่วย 105 คนนี้เสียชีวิตในปี 2564 จำนวน 10 คน

จงหาความชุกในปี 2564 (1 มกราคม – 31 ธันวาคม 2564)

- $= 105 / [(5000 + 4900) / 2] = 0.021 = 2.1\% = 21 \text{ per } 1000$

Period Prevalence

59



Incidence

Incidence (1) อุบัติการณ์

61

๕

- ▶ Measure **happening or occurrence** of “events/processes” during a specified period of time
- ▶ Count **only new cases**, i.e. new events
- ▶ วัดสัดส่วนหรืออัตราของผู้ป่วยที่เกิดโรค “**รายใหม่**” (**new case**) ภายในช่วงเวลาใดเวลาหนึ่ง
ที่พัฒนามาจาก**ประชากรที่มีความเสี่ยงต่อการเกิดโรค (Population at risk)** แต่ไม่เคยเป็นโรคมาก่อน

1. Incidence proportion
2. Incidence rate ; เวลาเป็นตัวหาร

Incidence (2)

62


- ▶ **Incidence proportion:** จำนวนการเกิดโรคหรือเหตุการณ์ใดเหตุการณ์หนึ่งใหม่ภายในช่วงเวลาใดเวลาหนึ่ง เปรียบเทียบกับจำนวนของประชากรที่มีโอกาสที่จะเกิดโรคหรือเหตุการณ์นั้นๆทั้งหมด โดยไม่ได้คำนึงถึงจำนวนประชากรที่สูญหายไประหว่างการติดตาม (Loss to follow - up)
Syn: **attack rate, risk, probability of getting disease, cumulative incidence**

$$\frac{\text{จำนวนผู้ป่วยรายใหม่ในช่วงเวลาที่กำหนด}}{\text{จำนวนคนที่เสี่ยงต่อการเกิดโรคทั้งหมดในช่วงเวลาที่กำหนด}}$$

- ▶ Example: ในระหว่างการระบาดของเชื้อไวรัสโคโรนา 2019 ผู้ป่วย 50 จาก 2000 คนเสียชีวิต
จงหาความเสี่ยงต่อการเสียชีวิตในผู้ป่วยกลุ่มนี้
 $= 50/2000 = 0.025 = 25 \text{ per } 1000 = 2.5\%$

Incidence proportion


63



$$= 4 / (8 - 1) = 4 / 7 = 57.14\%$$

Incidence proportion

64



$$= 2/6 = 33.33\%$$

Incidence proportion

65

```
. clear
```

```
. use "C:\Users\Thananan\Desktop\practice data sets\lowbwt_dat.dta"
```

```
. tab low
```

low birth weight	Freq.	Percent	Cum.
birth weight ge 2500g	130	68.78	68.78
birth weight lt 2500g	59	31.22	100.00
Total	189	100.00	

Incidence (3)

66

2. **Incidence rate**: การวัดอุบัติการณ์การเกิดโรคจากประชากรที่มีความเสี่ยงในการเกิดโรคที่มีระยะเวลาในการติดตามแต่ละรายแตกต่างกัน การวัดอุบัติการณ์แบบ Incidence density จะวัดตัวเลขเหมือนกับ incidence proportion แต่ตัวส่วนจะเปลี่ยนจากจำนวนคนที่เสี่ยงต่อการเกิดโรคเป็น ผลรวมของระยะเวลาที่ผู้ป่วยเสี่ยงต่อการเกิดโรค (**Time at risk**) การรายงานจะอยู่ในรูป **person - time**

$$\frac{\text{จำนวนผู้ป่วยรายใหม่ในช่วงเวลาที่กำหนด}}{\text{ผลรวมของระยะเวลาเสี่ยงที่จะเกิดโรค}}$$

Example: ในระหว่างการระบาดของเชื้อไวรัสโคโรนา 2019 ผู้ป่วย 50 จาก 2000 คนเสียชีวิต
จงหาความเสี่ยงต่อการเสียชีวิตในผู้ป่วยกลุ่มนี้
 $= 50/2000 = 0.025 = 25 \text{ per } 1000 = 2.5\%$

Incidence (4)

67

2. **Incidence rate**: การวัดอุบัติการณ์การเกิดโรคจากประชากรที่มีความเสี่ยงในการเกิดโรคที่มีระยะเวลาในการติดตามแต่ละรายแตกต่างกัน การวัดอุบัติการณ์แบบ Incidence density จะวัดพิเศษเหมือนกับ incidence proportion แต่ตัวส่วนจะเปลี่ยนจากจำนวนคนที่เสี่ยงต่อการเกิดโรค เป็น ผลรวมของระยะเวลาที่ผู้ป่วยเสี่ยงต่อการเกิดโรค (**Time at risk**) การรายงานจะอยู่ในรูป **person - time**

$$\frac{\text{จำนวนผู้ป่วยรายใหม่ในช่วงเวลาที่กำหนด}}{\text{ผลรวมของระยะเวลาเสี่ยงที่จะเกิดโรค}}$$

Incidence rate

จำนวนผู้ป่วยรายใหม่ในช่วงเวลาที่กำหนด
 ــ
 ผลรวมของระยะเวลาเสี่ยงที่จะเกิดโรค

68

$$= 3 / (3 + 3 + 4 + 1 + 2 + 2 + 4) = 3 / 18 = 0.17$$

ปี 2560	ปี 2561	ปี 2562	ปี 2563	ปี 2564
			 3	
			 3	
				 4
	 1			
		 2		
		X 2		
				 4
				 4

Other measure of frequency

69



- ▶ Attack rate = incidence proportion
- ▶ Crude mortality rate
- ▶ Case-fatality rate

Attack rate (AR) (1)

70





- ▶
$$\frac{\text{Number of incident cases during an epidemic period}}{\text{Population at risk at the beginning of the epidemic period}}$$
- ▶ **Overall attack rate:** among total population
- ▶ **Specific attack rate:** among subpopulation
 - ▶ Age-specific attack rate
 - ▶ Gender-specific attack rate
 - ▶ Food-specific attack rate
- ▶ Differences among specific attack rates are important for generating hypotheses!

Attack rate (AR) (2)

71

```
. use "C:\Users\Thananan\Desktop\practice data sets\hiv vaccine trial.dta"
```



Male AR = 25.25%

Female AR = 27.32%

Overall AR = 26.04%

```
. tabulate dem_sex endpt_infect, chi2 row
```

Key			
frequency			
row percentage			
Sex	end point - confirmed HIV +		Total
	No	Yes	
Male	222 74.75	75 25.25	297 100.00
Female	133 72.68	50 27.32	183 100.00
Total	355 73.96	125 26.04	480 100.00

Pearson chi2(1) = 0.2519 Pr = 0.616

Pr > 0.05 ไม่มีความแตกต่างกัน AR ระหว่าง male และ female

Attack rate (AR) (3)

72

หา attack rate ของกลุ่มที่ได้และไม่ได้วัคซีน

```
. use "C:\Users\Thananan\Desktop\practice data sets\hiv vaccine trial.d
```

AR ในกลุ่มที่ได้ placebo = 30.58
AR ในกลุ่มที่ได้ vaccine = 21.43
Overall AR = 26.04

$Pr < 0.05$ มีความแตกต่างกันของ AR
ระหว่าง กลุ่ม placebo และกลุ่มที่ได้
vaccine

```
. tabulate trtm endpt_infect, chi2 row
```

Key			
frequency			
row percentage			
vaccine or placebo group	end point - confirmed HIV +		Total
	No	Yes	
Placebo	168 69.42	74 30.58	242 100.00
Vaccine	187 78.57	51 21.43	238 100.00
Total	355 73.96	125 26.04	480 100.00
Pearson chi2(1) = 5.2159 Pr = 0.022			

Crude mortality rate

- ▶ It is a proportion of total deaths by all causes among total population in a given period
- ▶
$$\frac{\text{จำนวนผู้เสียชีวิตทั้งหมดในปีปฏิทินนั้น}}{\text{ประชากรกลางปี}}$$

Case-fatality rate

- ▶ It is a proportion of deaths by a specific disease among all deaths in a given period
- ▶
$$\frac{\text{จำนวนผู้เสียชีวิตจากโรคนั้นในปีปฏิทินนั้น}}{\text{จำนวนผู้เสียชีวิตทั้งหมดในปีปฏิทินนั้น}}$$



Comparison testing

Comparison between group

75



► Categorical outcome

- Chi-square (χ^2) test

► Continuous Variable

❖ Normal Distribution


- t-test (2 groups) F-test/ANOVA (≥ 2 groups)

❖ Not normal Distribution


- Wilcoxon test, Mann-Whitney U test

Chi-square (c2) test

76



.1815262





```
. tab trtmt endpt_infect, chi2
```

vaccine or placebo group	end point - confirmed HIV +		Total
	No	Yes	
Placebo	168	74	242
Vaccine	187	51	238
Total	355	125	480

Pearson chi2(1) = 5.2159 Pr = 0.022

t-test (2 groups)

77



```
. ttest scr_inclage, by(endpt_infect)
```

Two-sample t test with equal variances



Group	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf. Interval]	
No	355	23.47324	.1844279	3.474888	23.11053	23.83595
Yes	125	23.872	.2835207	3.169858	23.31083	24.43317
combined	480	23.57708	.1551587	3.399358	23.27221	23.88196
diff		-.3987606	.3534473		-1.093263	.2957419

diff = mean(No) - mean(Yes) t = -1.1282
Ho: diff = 0 degrees of freedom = 478

Ha: diff < 0	Ha: diff != 0	Ha: diff > 0
Pr(T < t) = 0.1299	Pr(T > t) = 0.2598	Pr(T > t) = 0.8701

F-test/ANOVA (≥ 2 groups)

78





```
. oneway endpt_infect trtmt
```

Analysis of Variance					
Source	SS	df	MS	F	Prob > F
Between groups	1.00458727	1	1.00458727	5.25	0.0224
Within groups	91.4433294	478	.191304036		
Total	92.4479167	479	.193001914		

Bartlett's test for equal variances: $\chi^2(1) = 3.1913$ Prob> $\chi^2 = 0.074$

Wilcoxon test,

79



```
. ranksum scr_inc1age, by(endpt_infect) exact
```

Two-sample Wilcoxon rank-sum (Mann-Whitney) test

endpt_infect	obs	rank sum	expected
No	355	83815	85377.5
Yes	125	31625	30062.5
combined	480	115440	115440

unadjusted variance 1778697.92

adjustment for ties -13277.47

adjusted variance 1765420.45

Ho: scr_inc1age(endpt_infect==No) = scr_inc1age(endpt_infect==Yes)

z = -1.176

Prob > |z| = 0.2396

Exact Prob = 0.2400

Measures of association

การวัดความสัมพันธ์

Measures of association

81

- ▶ การวัดความสัมพันธ์ทางสถิติระหว่างตัวแปรต้นและตัวแปรตาม
- ▶ อาจจะเป็นสาเหตุหรือไม่ใช่สาเหตุก็ได้
- ▶ มักใช้ใน observation study
- ▶ การเลือกใช้ขึ้นอยู่กับ study design
- ▶ แบ่งเป็น 2 ประเภทตามการเปรียบเทียบ
 - ▶ **Ratio** scale
 - Risk ratio: ratio of incidence proportion (risk)
 - Rate ratio: ratio of incidence rate
 - Odds ratio: ratio of odds
 - Prevalence ratio: ratio of prevalence
 - ▶ **Difference** scale
 - Risk difference
 - Rate difference
 - Prevalence difference

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

Prevalence ratio

82

- ▶ ใช้ใน cross-sectional study

- ▶
$$\frac{\text{Prevalence ในกลุ่ม exposed}}{\text{Prevalence ในกลุ่ม unexposed}}$$

- ▶
$$\frac{Pe}{Pu} = \frac{A(A+B)}{C/(C+D)}$$

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

- ▶ **Interpretation:** ความชุกของการป่วยในกลุ่ม exposed เป็น PR เท่าของกลุ่ม unexposed

prevalence of having the disease in exposed group is 6 times of that in unexposed group

Prevalence difference (PD)

83



- ▶ A difference of two prevalence
- ▶ Cross-sectional study
- ▶ $PE - Pu$
- ▶ Prevalence of having disease in exposed group is PD higher than that in unexposed group
- ▶ ความชุกของการป่วยในกลุ่ม exposed สูงกว่า unexposed PD%



Risk Ratio

Risk ratio / Relative risk (RR) (1)

85

▶ ใช้ใน Cohort study

▶ $\frac{\text{Risk ของกลุ่ม } exposed}{\text{Risk ของกลุ่ม } unexposed}$

▶ $\frac{\text{Incidence ของกลุ่ม } exposed}{\text{Incidence ของกลุ่ม } unexposed}$

▶ IE / Iu

▶ $\frac{A/(A+B)}{C/(C+D)}$

$$= \frac{60/100}{10/100} = \frac{0.6}{0.1} = 6$$

ความเสี่ยงต่อการเกิดอาการท้องเสียในกลุ่มที่กินไข่ต้มเป็น 6 เท่าของ
คนที่ไม่ได้กิน

	ท้องเสีย	ไม่มี ท้องเสีย	Total
กินไข่ต้ม	60	40	100
ไม่ได้กิน ไข่ต้ม	10	90	100
Total	70	130	200

Risk ratio / Relative risk (RR) (2)

86

```
. clear  
  
. use "C:\Users\Thananan\Desktop\practice data sets\hiv vaccine trial.dta"  
  
. tab trtmt endpt_infect
```

vaccine or placebo group	end point - confirmed HIV +		Total
	No	Yes	
Placebo	168	74	242
Vaccine	187	51	238
Total	355	125	480

$$\blacktriangleright = \frac{51/238}{74/242} = 0.7$$

ความเสี่ยงต่อการติดเชื้อในคนที่**ได้วัคซีน**เป็น **0.7 เท่า**ของคนที่**ไม่ได้วัคซีน**

$$\blacktriangleright = \frac{1}{0.7} = 1.43$$

ความเสี่ยงต่อการติดเชื้อในคนที่**ไม่ได้วัคซีน**เป็น **1.43 เท่า**ของคนที่**ได้วัคซีน**

Risk ratio / Relative risk (RR) (3)

87

Statistics | User | Window | Help

- Summaries, tables, and tests
- Linear models and related
- Binary outcomes
 - Ordinal outcomes
 - Categorical outcomes
 - Count outcomes
 - Fractional outcomes
 - Generalized linear models
 - Choice models
- Time series
 - Multivariate time series
 - Spatial autoregressive models
 - Longitudinal/panel data
 - Multilevel mixed-effects models
 - Survival analysis
- Epidemiology and related
 - ROC analysis
 - Tables for epidemiologists
 - Incidence-rate ratio
 - Incidence-rate ratio calculator
 - Cohort study risk ratio etc. calculator
 - Case-control odds ratio
 - Case-control odds ratio calculator
 - Tobit odds of failure by category
 - Ratio of odds of failure for two categories
 - Matched case-control studies
 - Matched case-control calculator
 - Other
- Sample selection models
- Treatment effects
- SEM (structural equation modeling)
- LCA (latent class analysis)
- FMM (finite mixture models)
- IRT (item response theory)
- Multivariate analysis
- Survey data analysis
- Upro
- Meta-analysis
- Multiple imputation
- Nonparametric analysis
- Exact statistics
- Resampling
- Power, precision, and sample size
- Bayesian analysis
- Postestimation
- Other

int - confirmed
HIV +

No	Yes	Total
168	74	242
187	51	238
355	125	480

anan\Desktop\practice data sets\hiv vaccine

vaccine or placebo group	end point - confirmed HIV +		Total
	No	Yes	
Placebo	168	74	242
Vaccine	187	51	238
Total	355	125	480

csi - Cohort studies

	Exposed	Unexposed
Cases	51	74
Noncases	187	168

☒ Report odds ratios
☐ Woolf approximation
☐ Fisher's exact p
95 Confidence level

OK Cancel Submit

. csi 51 74 187 168, or

	Exposed	Unexposed	Total
Cases	51	74	125
Noncases	187	168	355
Total	238	242	480
Risk	.2142857	.3057851	.2604167
Point estimate		[95% Conf. Interval]	
Risk difference	-.0914994		-.1695202 -.0134786
Risk ratio	.7007722		.514711 .9540921
Prev. frac. ex.	.2992278		.0459079 .485289
Prev. frac. pop	.1483671		
Odds ratio	.6191646		.4101872 .9346859

chi2(1) = 5.22 Pr>chi2 = 0.0224

ความเสี่ยงต่อการติดเชื้อในคนที่**ได้วัคซีน**เป็น **0.7** เท่าของคนที่ไม่**ได้วัคซีน**

Risk ratio / Relative risk (RR) (4)

88

Statistics	User	Window	Help
Summaries, tables, and tests			
Linear models and related			
Binary outcomes			
Ordinal outcomes			
Categorical outcomes			
Count outcomes			
Fractional outcomes			
Generalized linear models			
Choice models			
Time series			
Multivariate time series			
Spatial autoregressive models			
Longitudinal/panel data			
Multilevel mixed-effects models			
Survival analysis			
Epidemiology and related			
Endogenous covariates			
Sample-selection models			
Treatment effects			
SEM (structural equation modeling)			
LCA (latent class analysis)			
FMM (finite mixture models)			
IRT (item response theory)			
Multivariate analysis			
Survey data analysis			
Lasso			
Meta-analysis			
Multiple imputation			
Nonparametric analysis			
Exact statistics			
Resampling			
Power, precision, and sample size			
Bayesian analysis			
Postestimation			
Other			

```
. cs endpt_infect trtm
```

	vaccine or placebo group		Total
	Exposed	Unexposed	
Cases	51	74	125
Noncases	187	168	355
Total	238	242	480
Risk	.2142857	.3057851	.2604167
Point estimate		[95% Conf. Interval]	
Risk difference	-.0914994	-.1695202	-.0134786
Risk ratio	.7007722	.514711	.9540921
Prev. frac. ex.	.2992278	.0459079	.485289
Prev. frac. pop	.1483671		
chi2(1) = 5.22 Pr>chi2 = 0.0224			

```
. tab endpt_infect trtm
```

end point - confirmed HIV +	vaccine or placebo group		Total
	Placebo	Vaccine	
No	168	187	355
Yes	74	51	125
Total	242	238	480

ความเสี่ยงต่อการติดเชื้อในคนที่**ได้วัคซีน**เป็น **0.7 เท่า** ของคนที่**ไม่ได้วัคซีน**
Vaccine Efficacy (VE) = $1 - RR = 1 - 0.7 = 0.3 = 30\%$
วัคซีนมีประสิทธิภาพป้องกันการติดเชื้อได้ร้อยละ 30

Vaccine Efficacy(VE)

- ▶ Vaccine Efficacy = RCT effect
- ▶ Vaccine Effective = real world effect
- ▶ Vaccine efficiency = Cost / Effect

- ▶ Vaccine Efficacy(VE)

$$\begin{aligned} VE &= \frac{(AR \text{ nonvaccine} - AR \text{ vaccine})}{AR \text{ nonvaccine}} \\ &= \frac{AR \text{ nonvaccine}}{AR \text{ nonvaccine}} - \frac{AR \text{ vaccine}}{AR \text{ nonvaccine}} \\ &= 1 - \frac{AR \text{ vaccine}}{AR \text{ nonvaccine}} = 1 - RR \end{aligned}$$

- ▶ $RR = \frac{Incidence \text{ ของกลุ่ม } exposed}{Incidence \text{ ของกลุ่ม } unexposed} = \frac{AR \text{ ของกลุ่ม } exposed}{AR \text{ ของกลุ่ม } unexposed} = \frac{AR \text{ ของกลุ่ม } vaccine}{AR \text{ ของกลุ่ม } nonvaccine}$

Risk difference (RD, attributable risk)

90

- ▶ difference of two incidence proportions (exposed vs unexposed group)
- ▶ Cohort study
- ▶ $IE - Iu$
- ▶ $= (51/238) - (74/242)$
- ▶ $= 21.43 - 30.58$
- ▶ $= -0.09 = 9\%$

```
. cs endpt_infect trtmt
```

	vaccine or placebo group		Total
	Exposed	Unexposed	
Cases	51	74	125
Noncases	187	168	355
Total	238	242	480
Risk	.2142857	.3057851	.2604167
Point estimate		[95% Conf. Interval]	
Risk difference	-.0914994		-.1695202 -.0134786
Risk ratio	.7007722		.514711 .9540921
Prev. frac. ex.	.2992278		.0459079 .485289
Prev. frac. pop	.1483671		

chi2(1) = 5.22 Pr>chi2 = 0.0224

```
. tab endpt_infect trtmt, col
```

Key			
frequency column percentage			
end point - confirmed HIV +	vaccine or placebo group		Total
	Placebo	Vaccine	
No	168 69.42	187 78.57	355 73.96
Yes	74 30.58	51 21.43	125 26.04
Total	242 100.00	238 100.00	480 100.00

- ▶ ความเสี่ยงต่อการติดเชื้อในคนที่ได้วัคซีนคือ 9% น้อยกว่าคนที่ไม่ได้วัคซีน

Rate ratio / Incidence rate ratio (IRR) (1)

91

- ▶ A ratio of two incidence rates
- ▶ Used in RCT or Cohort study (with person-time data)
- ▶ Rate ratio (IRR) = $[A/TE] / [B/TU]$

	No. of sick	Person-time	Incidence rate
Exposed	A	TE	A/TE
Unexposed	B	TU	B/TU
Total	A+B	TE+TU	$(A+B)/(TE+TU)$

Odds Ratio (OR)

Odds ratio

93

- Use in Case-control, cohort, cross-sectional study

- Odds

$$\begin{aligned} &= \frac{\text{โอกาสเกิดเหตุการณ์}}{\text{โอกาสในการไม่เกิดเหตุการณ์}} \\ &= \frac{P}{1-P} \end{aligned}$$

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

ไม่มี Odds difference เพราะตัวหารคนละตัวกัน

Disease odds ratio (cohort study)

94

► $\frac{\text{odds ของการเกิดโรคในกลุ่ม } exposed}{\text{odds ของการเกิดโรคในกลุ่ม } unexposed}$

► $\frac{\frac{\text{โอกาสของการเกิดโรคในกลุ่ม } exposed}{\text{โอกาสของการไม่เกิดโรคในกลุ่ม } exposed}}{\frac{\text{โอกาสของการเกิดโรคในกลุ่ม } unexposed}{\text{โอกาสของการไม่เกิดโรคในกลุ่ม } unexposed}}$

► $\frac{\frac{A/(A+B)}{B/(A+B)}}{\frac{C/(C+D)}{D/(C+D)}} = \frac{\frac{A}{B}}{\frac{C}{D}} = \frac{A/B}{C/D} = AD/CB$

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

► **Interpretation:** การเกิดโรค ในกลุ่ม **exposed** เป็น OR เท่า ของกลุ่ม **unexposed**

Exposure odds ratio (case-control study)

95

► $\frac{\text{odds ของการ exposed ในกลุ่มป่วย}}{\text{odds ของการ exposed ในกลุ่มไม่ป่วย}}$

► $\frac{\frac{\text{โอกาสของ exposed ในกลุ่มป่วย}}{\text{โอกาสของการ unexposed ในกลุ่มป่วย}}}{\frac{\text{โอกาสของ exposed ในกลุ่มไม่ป่วย}}{\text{โอกาสของการ unexposed ในกลุ่มไม่ป่วย}}}$

►
$$\frac{\frac{A/(A+C)}{C/(A+C)}}{\frac{B/(B+D)}{D/(B+D)}} = \frac{\frac{A}{C}}{\frac{B}{D}} = \frac{A/C}{B/D} = AD/CB$$

	Case	Non-case	Total
Exposed	A	B	A+B
Not exposed	C	D	C+D
Total	A+C	B+D	A+B+C+D

► **Interpretation:** การ exposed ในกลุ่มป่วย เป็น OR เท่า ของกลุ่มไม่ป่วย

Summaries, tables, and tests ▶

Linear models and related ▶

Binary outcomes ▶

Ordinal outcomes ▶

Categorical outcomes ▶

Count outcomes ▶

Fractional outcomes ▶

Generalized linear models ▶

Choice models ▶

Time series ▶

Multivariate time series ▶

Spatial autoregressive models ▶

Longitudinal/panel data ▶

Multilevel mixed-effects models ▶

Survival analysis ▶

Epidemiology and related ▶

Endogenous covariates ▶

Sample-selection models ▶

Treatment effects ▶

SEM (structural equation modeling) ▶

LCA (latent class analysis) ▶

FMM (finite mixture models) ▶

IRT (item response theory) ▶

Multivariate analysis ▶

Survey data analysis ▶

Lasso ▶

Meta-analysis ▶

Multiple imputation ▶

Nonparametric analysis ▶

Exact statistics ▶

Resampling ▶

Power, precision, and sample size ▶

Bayesian analysis ▶

Postestimation ▶

Other ▶

`.infect, chi row`

point - confirmed

HIV +

No

Yes

Total

ROC analysis ▶

Tables for epidemiologists ▶

Other ▶

133

50

72.68

27.32

355

125

73.96

26.04

`chi2(1) = 0.2519`

Incidence-rate ratio

Incidence-rate ratio calculator

Cohort study risk-ratio etc.

Cohort study risk-ratio etc. calculator

Case-control odds ratio

Case-control odds-ratio calculator

Tabulate odds of failure by category

Ratio of odds of failure for two categories

Matched case-control studies

Matched case-control calculator

cci - Case-control studies

	Exposed	Unexposed
Cases	51	74
Controls	187	168

☒ Exact confidence intervals
☐ Cornfield approximation
☐ Woolf approximation

☐ Fisher's exact p
 95 Confidence level

`. cci 51 74 187 168`

	Exposed	Unexposed	Total	Proportion Exposed
Cases	51	74	125	0.4080
Controls	187	168	355	0.5268
Total	238	242	480	0.4958
Point estimate		[95% Conf. Interval]		
Odds ratio	.6191646	.4002905	.9546679	(exact)
Prev. frac. ex.	.3808354	.0453321	.5997095	(exact)
Prev. frac. pop	.2006091			

`chi2(1) = 5.22 Pr>chi2 = 0.0224`

Statistics

User

Window

Help

Summaries, tables, and tests

Linear models and related

Binary outcomes

Ordinal outcomes

Categorical outcomes

Count outcomes

Fractional outcomes

Generalized linear models

Choice models

Time series

Multivariate time series

Spatial autoregressive models

Longitudinal/panel data

Multilevel mixed-effects models

Survival analysis

Epidemiology and related

Endogenous covariates

Sample-selection models

Treatment effects

SEM (structural equation modeling)

LCA (latent class analysis)

FMM (finite mixture models)

IRT (item response theory)

Multivariate analysis

Survey data analysis

Lasso

Meta-analysis

Multiple imputation

Nonparametric analysis

Exact statistics

Resampling

Power, precision, and sample size

Bayesian analysis

Postestimation

133

50

183

72.68

27.32

100.00

355

125

480

73.96

26.04

100.00

chi2(1) =

0.2519

Pr = 0.616

Exposed

Unexposed

Total

Proportion Exposed

51

74

125

0.4080

187

168

355

0.5268

Point estimate

.6191646

.3808354

.2006091

chi2(1) =

5.22

Pr>chi2 = 0.0224

ROC analysis

Tables for epidemiologists

Other

Incidence-rate ratio

Incidence-rate ratio calculator

Cohort study risk-ratio etc.

Cohort study risk-ratio etc. calculator

Case-control odds ratio

Case-control odds-ratio calculator

Tabulate odds of failure by category

Ratio of odds of failure for two categories

Matched case-control studies

Matched case-control calculator

cc - Case-control studies

Main

if/in

Weights

Options

Case variable:

endpt_infect

Exposed variable:

trtm

```
. cc endpt_infect trtm
```

	Exposed	Unexposed	Total	Proportion Exposed
Cases	51	74	125	0.4080
Controls	187	168	355	0.5268
Total	238	242	480	0.4958
	Point estimate		[95% Conf. Interval]	
Odds ratio	.6191646		.4002905	.9546679
Prev. frac. ex.	.3808354		.0453321	.5997095
Prev. frac. pop	.2006091			
	chi2(1) =		5.22	Pr>chi2 = 0.0224



Odds ratio

98

- ▶ ใน Case-control study
 - ▶ ถ้า Case และ control ในการศึกษาที่สามารถเป็นตัวแทนที่ดีในประชากร
 - ▶ Exposure OR = Disease OR
- ▶ ถ้าใน rare disease $OR \approx RR$
 - ▶ เราสามารถแปลผล OR แบบ RR ได้

Odds ratio in Logistic regression

99



- ▶ Binary logistic regression model
- ▶ Binary outcome เช่น case non-case ป่วยกับไม่ป่วย

$$\log \frac{p_i}{1 - p_i} = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

- ▶ $OR = \exp \beta$

File Edit Data Graphics Statistics User Window Help

Summaries, tables, and tests

Linear models and related

Binary outcomes

Ordinal outcomes

Categorical outcomes

Count outcomes

Fractional outcomes

Generalized linear models

Choice models

Time series

Multivariate time series

Spatial autoregressive models

Longitudinal/panel data

Multilevel mixed-effects models

Survival analysis

Epidemiology and related

Endogenous covariates

Sample-selection models

Treatment effects

SEM (structural equation modeling)

LCA (latent class analysis)

FMM (finite mixture models)

IRT (item response theory)

Multivariate analysis

Survey data analysis

Lasso

Meta-analysis

Multiple imputation

Nonparametric analysis

Exact statistics

Resampling

Power, precision, and sample size

Bayesian analysis

Postestimation

Other

History

Filter commands here

Command

1 use "C:\Users\Thananan\De...

2 tab vacno

3 tab trmt

4 tab endpt_infect

5 tab trmt endpt_infect

6 clear

7 use "C:\Users\Thananan\De...

8 tab trmt endpt_infect

9 tab endpt_infect trmt

10 csi 74 51 168 187, or

11 cs endpt_infect trmt

12 label define ENDPT_JN 0 "...

13 replace endpt_infect = 2 if ...

14 cs endpt_infect trmt

15 replace endpt_infect = 0 if ...

16 recode endpt_infect 0=1 1... 1

17 recode endpt_infect 0=1 1...

18 label define ENDPT_JN 0 "Y...

19 tab endpt_infect

20 cs endpt_infect trmt

21 label define ENDPT_JN 0 "...

22 recode endpt_infect 1=0 0...

23 cs endpt_infect trmt

24 disp 1/0.7

25 recode endpt_infect 1=0 0... 1

26 recode endpt_infect 1=0 0...

27 cs infect2 trmt

28 disp (187/355)/(238/480)

29 disp (187/238)/(168/242)

30 logistic endpt_infect trmt

31 logistic endpt_infect trmt

32 disp 1/0.7

33 csi 51 74 187 168, or

34 **tab sex** 1

35 **tab sex** 1

36 tab dem_sex

37 tab dem_sex endpt_infect

38 tab dem_sex endpt_infect, r...

39 tab dem_sex endpt_infect, ...

40 cci 51 74 187 168

Point estimate

Logistic regression

Probit regression

Complementary log-log regression

Conditional logistic regression

Exact logistic regression

Skewed logistic regression

Probit model with endogenous covariates

Probit model with sample selection

Heteroskedastic probit regression

Probit with endogeneity, selection, and treatment

GLM for the binomial family

Bivariate probit regression

Seemingly unrelated bivariate probit regression

Panel regression

Multilevel mixed-effects regression

FMM (finite mixture models)

Nonparametric regression

Treatment effects

Lasso inferential models

Bayesian regression

Postestimation

chi2(1) = 5.

logistic - Logistic regression, reporting odds ratios

Model by/if/in Weights SE/Robust Reporting Maximization

Dependent variable: endpt_infect

Independent variables: trmt

☐ Suppress constant term

Options

Offset variable:

☐ Retain perfect predictor variables

Constraints:

Manage...

OK Cancel Submit

logistic - Logistic regression, reporting odds ratios

Model by/if/in Weights SE/Robust Reporting Maximization

95 Confidence level

☒ Report odds ratios (default)

☐ Report estimated coefficients

☐ Do not report constraints

☒ Report p-values, test statistics, and confidence intervals

☐ Suppress confidence intervals

☐ Suppress p-values and test statistics

Factor-variable reporting options

Set table formats

OK Cancel Submit

100



Odds ratio in Logistic regression

101



Report odds ratios

```
. logistic endpt_infect trtm
```

Logistic regression Number of obs = 480
 LR chi2(1) = 5.24
 Prob > chi2 = 0.0221
Log likelihood = -272.65617 Pseudo R2 = 0.0095

endpt_infect	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
trtm	.6191646	.1304974	-2.27	0.023	.4096413	.9358549
_cons	.4404762	.0614553	-5.88	0.000	.3350909	.5790049

Note: _cons estimates baseline odds.

OR = $\exp \beta = \exp 0.479 = e^{0.479}$
Coef. = $\ln(\text{OR}) = \ln 0.619 = 0.479$

Report coefficients

```
. logit endpt_infect trtm
```

Iteration 0: log likelihood = -275.2763
Iteration 1: log likelihood = -272.66478
Iteration 2: log likelihood = -272.65617
Iteration 3: log likelihood = -272.65617

Logistic regression Number of obs = 480
 LR chi2(1) = 5.24
 Prob > chi2 = 0.0221
Log likelihood = -272.65617 Pseudo R2 = 0.0095

endpt_infect	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
trtm	-.4793841	.2107637	-2.27	0.023	-.8924733	-.0662949
_cons	-.8198989	.1395202	-5.88	0.000	-1.093354	-.5464443



Regression model

Regression model

- ❖ Prediction of outcome from exposures
- ❖ Hypothesis testing with adjusted (controlled) for confounding other variables
- ▶ Simple $Y \square X$; Outcome $\square$ Factors
 - ▶ BP $\square$ Drug (A/B) ; $BP = a + b(\text{Drug})$
 - ▶ BP $\square$ Age ; $BP = a + b(\text{Age})$
- ▶ Multiple $Y \square X1 X2 X3$
- ▶ BP $\square$ Drug(A/B) Sex (M/F) Age
 - $BP = a + b1(\text{Drug}) + b2(\text{Sex}) + b3(\text{Age})$
 - $BP = 100 + 3 \text{ Drug} + 5 \text{ Sex} - 7 \text{ Age}$
 - $A=0 / B=1 \quad M=0 / F=1$

Multi-variables analysis

104

- ▶ Linear Regression
 - ❖ Y = continuous + normal distribution
 - ❖ Injury severity score
- ▶ Logistic Regression
 - ❖ Y = Categorical
 - ❖ Dead/ severity of injury/ bone fracture
- ▶ Poisson Regression
 - ❖ Y = Incidence/count
 - ❖ Dead
- ▶ Cox's Proportional Hazard Regression
 - ❖ Y = Time to event
 - ▶ Time from injury to dead

X= continuous / categorical
; sex, age, alcohol drinking

$$y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

$$\log \frac{p_i}{1 - p_i} = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki} \quad \text{OR} = \exp \beta$$

$$\log[\text{count}] = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

$$\log[\text{count or cases / time}] = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

$$\log[\text{rate} = \lambda] = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki} \quad \text{IRR} = \exp \beta$$

$$\log(Hz_t) = \log(Hz_0) + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

$$\log(\lambda_t) = \log(\lambda_0) + \beta_1 x_{1i} + \dots + \beta_K x_{Ki} \quad \text{HR} = \exp \beta$$

Note: If $P_0(T)$ is small, when comparing two groups
 $OR(t) \approx RR(t) \approx IRR(t) \approx HR(t) \approx K$

Principles for studying association

105

- Start with **graphical display: scatterplots**
 - Display the relationship between two quantitative variables.
 - The values of one variable appear on the horizontal axis (the x axis) and the values of the other variable on the vertical axis (the y axis).
 - Each individual is the point in the plot fixed by the values of both variables for that individual.
 - In regression, usually call **the explanatory variable x and the response variable y**.
- Look for **overall patterns** and for striking deviations from the pattern :
interpreting scatterplots
 - Overall pattern: the relationship has ...
 - ◆ **form** (linear relationships, curved relationships, clusters)
 - ◆ **direction** (positive/negative association)
 - ◆ **strength** (how close the points follow a clear form?)
 - ◆ **Outliers**
 - For a categorical x and quantitative y, show the distributions of y for each category of x.
- When the overall pattern is quite regular, use a compact **mathematical model** to describe it.



Linear Regression

Y = CONTINUOUS + NORMAL DISTRIBUTION

$$y_i = \beta_0 + \beta_1 x_{1i} + \epsilon_i + \beta_K x_{Ki}$$

Normal distribution of Y

107


```
. use "C:\Users\Thananan\Desktop\practice data sets\lowbwt_dat.dta"

. hist bwt
(bin=13, start=709, width=329.30769)
```

```
. swilk bwt
```

Shapiro-Wilk W test for normal data


Variable	Obs	W	V	z	Prob>z
bwt	189	0.99258	1.053	0.119	0.45247




Graph - Graph

File Edit Object Graph Tools Help

Graph x



108



Textbox properties

Text Box Format Advanced

Text:

Density


Text styles

Size: Medium small

Color: Black


Margin: Zero

OK Cancel Apply



Objects

- Graph
 - plotregion1
 - plot1
 - yaxis1
 - title
 - xaxis1
 - title
 - legend
 - key region
 - note
 - caption
 - subtitle
 - title
 - positional titles
 - right 1
 - right 2
 - left 1
 - left 2
 - top 1
 - top 2
 - bottom 1
 - bottom 2
 - note
 - caption
 - subtitle
 - title

Color: Save Margin: More...

Objects

- Graph
 - plotregion1
 - plot1
 - yaxis1
 - xaxis1
 - legend
 - positional titles
 - note
 - caption
 - subtitle
 - title

nanan\Desktop\practice data se

width=329.30769)

Shapiro-Wilk W test for normal

Obs	W	V	Z	Pr > Z
189	0.99258	1.053	0.119	0.45247

- Symmetry plot
- Quantiles plot
- Normal quantile plot
- Normal probability plot, standardized
- Chi-squared quantile plot
- Chi-squared probability plot
- Quantile-quantile plot
- Stem-and-leaf display
- Letter-value display
- Generate cumulative distribution
- Skewness and kurtosis normality test
- Shapiro-Wilk normality test
- Shapiro-Francia normality test
- Ladder of powers
- Ladder-of-powers histograms
- Ladder-of-powers quantile-normal plot

gledder - Ladder-of-powers histograms

Main
if/in
Density plots
Y axis
X axis
Titles
Legend
Overall

Data
Variable:
bwt


Bins
☐
10
Number of bins

Y axis
☒ Density
☐ Fraction
☐ Frequency
☐ Percent

Bar properties
Combine properties






☐ Add height labels to bars
Bar label properties

?
OK
Cancel
Submit





scatterplots

113



Linear regression

114



. regress bwt age						
Source	SS	df	MS	Number of obs	=	189
Model	806926.913	1	806926.913	F(1, 187)	=	1.52
Residual	99110125.7	187	530000.672	Prob > F	=	0.2188
				R-squared	=	0.0081
				Adj R-squared	=	0.0028
Total	99917052.6	188	531473.684	Root MSE	=	728.01

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
age	12.36433	10.02055	1.23	0.219	-7.403527	32.13219
_cons	2657.333	238.804	11.13	0.000	2186.236	3128.429

$$Y = a + bx$$



ทุก 1 หน่วย x ที่เพิ่มขึ้น จะเพิ่ม y ขึ้น b หน่วย

$$\text{Bwt} = 2657.33 + 12.36 (\text{age})$$

ถ้าแม่มีอายุเพิ่มขึ้น 1 ปี ลูกจะมีน้ำหนักเพิ่มขึ้น 12.36 กรัม

Linear regression

115



`. regress bwt smoke`

Source	SS	df	MS	Number of obs	=	189
Model	3573406.24	1	3573406.24	F(1, 187)	=	6.94
Residual	96343646.4	187	515206.665	Prob > F	=	0.0092
				R-squared	=	0.0358
				Adj R-squared	=	0.0306
Total	99917052.6	188	531473.684	Root MSE	=	717.78

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
smoke	-281.7133	106.9687	-2.63	0.009	-492.7338	-70.69274
_cons	3054.957	66.93324	45.64	0.000	2922.915	3186.998

$$Y = a + bx$$

ทุก 1 หน่วย x ที่เพิ่มขึ้น จะเพิ่ม y ขึ้น b หน่วย

$$Bwt = 3054.957 - 281.7133 (age)$$

ถ้าแม่สูบบุหรี่ ลูกจะมีน้ำหนักลดลง 281.7133 กรัม

Univariate

116

. regress bwt smoke

Source	SS	df	MS	Number of obs	=	189
Model	3573406.24	1	3573406.24	F(1, 187)	=	6.94
Residual	96343646.4	187	515206.665	Prob > F	=	0.0092
				R-squared	=	0.0358
				Adj R-squared	=	0.0306
Total	99917052.6	188	531473.684	Root MSE	=	717.78

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
smoke	-281.7133	106.9687	-2.63	0.009	-492.7338	-70.69274
_cons	3054.957	66.93324	45.64	0.000	2922.915	3186.998

. regress bwt ht

Source	SS	df	MS	Number of obs	=	189
Model	2132014.49	1	2132014.49	F(1, 187)	=	4.08
Residual	97785038.2	187	522914.643	Prob > F	=	0.0449
				R-squared	=	0.0213
				Adj R-squared	=	0.0161
Total	99917052.6	188	531473.684	Root MSE	=	723.13

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ht	-435.5607	215.7094	-2.02	0.045	-861.0973	-10.02413
_cons	2972.311	54.35366	54.68	0.000	2865.086	3079.536

. regress bwt ui

Source	SS	df	MS	Number of obs	=	189
Model	8028747.44	1	8028747.44	F(1, 187)	=	16.34
Residual	91888305.2	187	491381.311	Prob > F	=	0.0001
				R-squared	=	0.0804
				Adj R-squared	=	0.0754
Total	99917052.6	188	531473.684	Root MSE	=	700.99

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ui	-580.1801	143.5318	-4.04	0.000	-863.3298	-297.0304
_cons	3030.609	55.24543	54.86	0.000	2921.624	3139.593


. regress bwt ptl

Source	SS	df	MS	Number of obs	=	189
Model	2392205.02	1	2392205.02	F(1, 187)	=	4.59
Residual	97524847.6	187	521523.249	Prob > F	=	0.0335
				R-squared	=	0.0239
				Adj R-squared	=	0.0187
Total	99917052.6	188	531473.684	Root MSE	=	722.17

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ptl	-228.6506	106.7603	-2.14	0.034	-439.26	-18.04114
_cons	2989.418	56.53494	52.88	0.000	2877.89	3100.947

Multivariate

117



```
. regress bwt smoke ptl ht ui
```

Source	SS	df	MS	Number of obs = 189
Model	14402866.8	4	3600716.7	F(4, 184) = 7.75
Residual	85514185.8	184	464751.01	Prob > F = 0.0000
Total	99917052.6	188	531473.684	R-squared = 0.1441
				Adj R-squared = 0.1255
				Root MSE = 681.73

bwt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
smoke	-234.4121	103.4714	-2.27	0.025	-438.555 -30.26921
ptl	-95.53186	105.1879	-0.91	0.365	-303.0614 111.9977
ht	-522.2454	204.6148	-2.55	0.012	-925.9383 -118.5526
ui	-568.9723	144.2281	-3.94	0.000	-853.5258 -284.4187
_cons	3172.589	68.24453	46.49	0.000	3037.947 3307.232

$$\text{Bwt} = 3172.59 - 234.41(\text{smoke}) - 95.53(\text{ptl}) - 522.2454(\text{ht}) - 568.97(\text{ui})$$

Baby birth weight will decrease 234.41g in smoking mother after adjusted for history of premature labor, hypertension, and uterine irritation with statistic significant.





Logistic Regression

Y = CATEGORICAL

$$\log \frac{p_i}{1 - p_i} = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

Logistic Regression

119



- ▶ Binary outcome
 - ▶ Outcome = yes/no
- ▶ Ordinal outcome
 - ▶ Outcome = level
 - ▶ Ex. Tumor grade
- ▶ Multinomial outcome
 - ▶ Outcome = category

Statistics User Window Help

Summaries, tables, and tests	
Linear models and related	
Binary outcomes	Logistic regression
Ordinal outcomes	Probit regression
Categorical outcomes	Complementary log-log regression

Statistics User Window Help

Summaries, tables, and tests	
Linear models and related	
Binary outcomes	
Ordinal outcomes	Ordered logistic regression
Categorical outcomes	Ordered probit regression
Count outcomes	Ordered probit with endogenous covariates

Statistics User Window Help

Summaries, tables, and tests	
Linear models and related	
Binary outcomes	
Ordinal outcomes	
Categorical outcomes	Multinomial logistic regression
Count outcomes	Multinomial probit regression

Binary Logistic regression

120



Report odds ratios

```
. logistic endpt_infect trtmt
```

```
Logistic regression              Number of obs   =      480
                                LR chi2(1)        =       5.24
                                Prob > chi2        =     0.0221
Log likelihood = -272.65617       Pseudo R2      =     0.0095
```

endpt_infect	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
trtmt	.6191646	.1304974	-2.27	0.023	.4096413	.9358549
_cons	.4404762	.0614553	-5.88	0.000	.3350909	.5790049

Note: `_cons` estimates baseline odds.

Report coefficients

```
. logit endpt_infect trtmt
```

```
Iteration 0:  log likelihood = -275.2763
Iteration 1:  log likelihood = -272.66478
Iteration 2:  log likelihood = -272.65617
Iteration 3:  log likelihood = -272.65617
```

```
Logistic regression              Number of obs   =      480
                                LR chi2(1)        =       5.24
                                Prob > chi2        =     0.0221
Log likelihood = -272.65617       Pseudo R2      =     0.0095
```

endpt_infect	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
trtmt	-.4793841	.2107637	-2.27	0.023	-.8924733	-.0662949
_cons	-.8198989	.1395202	-5.88	0.000	-1.093354	-.5464443

Interpretation: การได้รับวัคซีนในกลุ่มที่ติดเชื่อ เป็น 0.62 เท่า ของกลุ่มที่ไม่ติดเชื่อ



แปลแบบ disease OR = การติดเชื่อในกลุ่มได้รับวัคซีนเป็น 0.62 เท่าของกลุ่มที่ไม่ได้รับวัคซีน

แปลแบบ RR = คนที่ได้รับวัคซีนมีโอกาสติดเชื่อเป็น 0.62 เท่าของคนที่ไม่ได้รับ

Ordinal Logistic regression

121

- ▶ Outcome = level
- ▶ Ex. 1 2 3 4 5
- ▶ เป็นการเปรียบเทียบกับระดับที่สูงกว่าและต่ำกว่า
- ▶ 1 เทียบกับ 2, 2 เทียบกับ 1 และ 3, 3 เทียบกับ 2 และ 4, 4 เทียบกับ 3 และ 5, 5 เทียบกับ 4



Ordinal Logistic regression

122



```
. use "C:\Users\Thananan\Downloads\rti korat.dta"
```

```
. tab iss
```

level of severity	Freq.	Percent	Cum.
1	38	64.41	64.41
2	11	18.64	83.05
3	1	1.69	84.75
4	4	6.78	91.53
5	1	1.69	93.22
6	4	6.78	100.00
Total	59	100.00	

```
. ologit iss slept,or
```

Iteration 0: log likelihood = -50.928458

Iteration 1: log likelihood = -50.567058

Iteration 2: log likelihood = -50.56545

Iteration 3: log likelihood = -50.56545

Ordered logistic regression

Number of obs	=	44
LR chi2(1)	=	0.73
Prob > chi2	=	0.3942
Pseudo R2	=	0.0071

Log likelihood = -50.56545

iss	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
slept	1.874469	1.419475	0.83	0.407	.4249042	8.269241
/cut1	.8599954	.6808475			-.4744412	2.194432
/cut2	1.867402	.7317753			.4331486	3.301655
/cut3	2.571326	.7959231			1.011345	4.131306
/cut4	2.820017	.8267848			1.199549	4.440486

Note: Estimates are transformed only in the first equation.

Ordinal Logistic regression

123

```
. ologit iss fal4,or
```

```
Iteration 0: log likelihood = -64.879232
Iteration 1: log likelihood = -61.732332
Iteration 2: log likelihood = -61.662334
Iteration 3: log likelihood = -61.662308
Iteration 4: log likelihood = -61.662308
```

```
Ordered logistic regression      Number of obs   =      59
                                LR chi2(1)          =      6.43
                                Prob > chi2          =     0.0112
                                Pseudo R2            =     0.0496
Log likelihood = -61.662308
```

iss	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
fal4	4.495933	2.86405	2.36	0.018	1.289965	15.66974
/cut1	1.585876	.5470079			.5137605	2.657992
/cut2	2.662984	.6141425			1.459287	3.866682
/cut3	2.799218	.6259402			1.572398	4.026038
/cut4	3.501766	.7021733			2.125531	4.878
/cut5	3.751654	.738761			2.303709	5.199599

Note: [Estimates are transformed](#) only in the first equation.

```
. ologit iss dambus,or
```

```
Iteration 0: log likelihood = -64.879232
Iteration 1: log likelihood = -56.912306
Iteration 2: log likelihood = -56.244907
Iteration 3: log likelihood = -56.241332
Iteration 4: log likelihood = -56.241331
```

```
Ordered logistic regression      Number of obs   =      59
                                LR chi2(1)          =     17.28
                                Prob > chi2          =     0.0000
                                Pseudo R2            =     0.1331
Log likelihood = -56.241331
```

iss	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
dambus	13.53989	3.971538	3.93	0.000	3.69495	49.61599
/cut1	1.256891	.3573746			.5564498	1.957333
/cut2	2.604729	.5040012			1.616905	3.592554
/cut3	2.787684	.5289695			1.750923	3.824445
/cut4	3.663075	.6500212			2.389057	4.937094
/cut5	3.939048	.6936303			2.579557	5.298538


Note: [Estimates are transformed](#) only in the first equation.

การตกจากเก้าอี้จะทำให้
การบาดเจ็บรุนแรงขึ้น 4.5
เท่า

การนั่งบริเวณที่มีการยุบตัวของตัวถึงรถ
จะทำให้การบาดเจ็บรุนแรงขึ้น 13.54
เท่า

Ordinal Logistic regression

124



The image shows the 'ologit - Ordered logistic regression' dialog box in SPSS. The 'Dependent variable' is 'iss' and the 'Independent variables' are 'fal4' and 'dambus'. The 'Options' tab is selected, showing 'Offset variable: (optional)' and 'Constraints:'. The 'Manage...' button is visible next to the constraints field. At the bottom, there are buttons for '?', a refresh icon, a save icon, 'OK', 'Cancel', and 'Submit'.

```
. ologit iss fal4 dambus, or
```

Iteration 0: log likelihood = -64.879232
Iteration 1: log likelihood = -54.674626
Iteration 2: log likelihood = -53.501901
Iteration 3: log likelihood = -53.492808
Iteration 4: log likelihood = -53.492806

Ordered logistic regression

Number of obs	=	59
LR chi2(2)	=	22.77
Prob > chi2	=	0.0000
Pseudo R2	=	0.1755

Log likelihood = -53.492806

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
iss						
fal4	4.69239	3.313033	2.19	0.029	1.176003	18.72318
dambus	13.41914	9.103078	3.83	0.000	3.550581	50.71661
/cut1	2.290707	.6576021			1.001831	3.579584
/cut2	3.748644	.7987795			2.183065	5.314223
/cut3	3.964235	.8323803			2.3328	5.595671
/cut4	4.940901	.9605194			3.058317	6.823484
/cut5	5.231272	.9959223			3.2793	7.183244

การตกจากเก้าอี้จะทำให้การบาดเจ็บรุนแรงขึ้น
4.69 เท่า
เมื่อคำนึงถึงตัวแปรรอบกวนจากการนั่งบริเวณที่มีการ

Multinomial Logistic regression

125

```
. use "C:\Users\Thananan\Desktop\Tobacco Project\Health Sit\Microdata HBS 2564\HBS64.dta"
```

```
. tab quitint
```

intention to quit	Freq.	Percent	Cum.
no	15,170	37.19	37.19
yes but never try	10,567	25.90	63.09
yes and try	15,057	36.91	100.00
Total	40,794	100.00	

```
. mlogit quitint smkhev, rrr
```

```
Iteration 0: log likelihood = -44287.48
Iteration 1: log likelihood = -44111.885
Iteration 2: log likelihood = -44111.75
Iteration 3: log likelihood = -44111.75
```

```
Multinomial logistic regression      Number of obs      =      40,794
                                      LR chi2(2)             =      351.46
                                      Prob > chi2            =      0.0000
Log likelihood = -44111.75           Pseudo R2          =      0.0040
```

quitint	RRR	Std. Err.	z	P> z	[95% Conf. Interval]	
no	(base outcome)					
yes_but_never_try						
smkhev	.7471556	.019123	-11.39	0.000	.7105997	.7855921
_cons	.8216297	.0157442	-10.25	0.000	.7913438	.8530746
yes_and_try						
smkhev	.6520336	.015163	-18.39	0.000	.6229818	.6824403
_cons	1.255548	.0216569	13.19	0.000	1.213811	1.298721

Note: _cons estimates baseline relative risk for each outcome.

คนที่สูบบุหรี่หนักจะมีความอยากเลิกแต่ไม่เคยพยายามเลิกเป็น 0.75 เท่าเมื่อเทียบกับคนที่ไม่อยากเลิก


คนที่อยากเลิกแต่ไม่เคยพยายามเลิกจะเป็นคนที่สูบบุหรี่หนักเป็น 0.75 เท่าเมื่อเทียบกับคนที่ไม่อยากเลิก

คนที่สูบบุหรี่หนักจะมีความอยากเลิกและพยายามเลิกบุหรืเป็น 0.65 เท่าของคนที่ไม่อยากเลิก


Confounding vs effect modification

126


Effect modification



Confounding




Confounding versus effect modification




Confounding

127



1. เป็น risk factor ของ outcome
 2. มีความสัมพันธ์กับ exposure
 3. ไม่เป็น intermediate
- รายงานผลเป็น Adjusted measure



Control of confounding

Study design

- ▶ Restriction
- ▶ Matching

Analytic

- ▶ Stratification
- ▶ Multivariate analysis
 - ▶ Crude measure (OR/RR)
 - ▶ Adjusted RR (OR/RR)

Degree of Confounding


$$= \frac{\text{Crude measure}}{\text{Adjusted measure}}$$

- >1 over estimation
- <1 under estimation


Effect modification/ Interaction

129

Effect modification



รายงานผลเป็น Crude measure จากการ stratified





Poisson Regression

Y = INCIDENCE / CONTINUOUS

$$\log[\textit{count}] = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

$$\log[\textit{count or cases / time}] = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

$$\log[\textit{rate} = \lambda] = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki}$$

```
. use "D:\practice data sets\rti korat.dta"
```


```
. swilk ais
```

Shapiro-Wilk W test for normal data

Variable	Obs	W	V	z	Prob>z
ais	59	0.59608	21.662	6.623	0.00000

```
. hist ais
```

```
(bin=7, start=0, width=10.714286)
```



poisson - Poisson regression

Model by/if/in Weights SE/Robust Reporting Maximization

Dependent variable: ais Independent variables: fal4

☐ Suppress constant term

Options

☒ Exposure variable: ☐ Offset variable:

Constraints: Manage...

OK Cancel Submit

```
. poisson ais fal4, irr
```

```
Iteration 0: log likelihood = -591.04958
Iteration 1: log likelihood = -590.86852
Iteration 2: log likelihood = -590.86834
Iteration 3: log likelihood = -590.86834
```

Poisson regression

Log likelihood = -590.86834

Number of obs = 59

LR chi2(1) = 267.53

Prob > chi2 = 0.0000

Pseudo R2 = 0.1846

	ais	IRR	Std. Err.	z	P> z	[95% Conf. Interval]
	fal4	4.777992	.5528086	13.52	0.000	3.808573 5.994163
	_cons	3.818182	.4165978	12.28	0.000	3.083067 4.728575

Note: _cons estimates baseline incidence rate.

Multivariate analysis; IRR

133

```
. poisson ais fal4 slept dambus hit, irr
```

```
Iteration 0:    log likelihood = -330.60085
```

```
Iteration 1:    log likelihood = -330.50745
```

```
Iteration 2:    log likelihood = -330.50742
```

```
Poisson regression              Number of obs   =          44
                                LR chi2(4)       =        540.21
                                Prob > chi2      =         0.0000
Log likelihood = -330.50742      Pseudo R2      =         0.4497
```

ais	IRR	Std. Err.	z	P> z	[95% Conf. Interval]	
fal4	4.178341	.5660355	10.56	0.000	3.204	5.448981
slept	1.150043	.1176251	1.37	0.172	.9411402	1.405316
dambus	3.856233	.3175042	16.39	0.000	3.281552	4.531555
hit	1.076447	.0107098	7.40	0.000	1.05566	1.097644
_cons	1.477969	.2629338	2.20	0.028	1.042881	2.094575

Note: `_cons` estimates baseline incidence rate.

- ผู้ที่ตกจากเก้าอี้จะมีความเสี่ยงที่จะมีค่า
รุนแรงการบาดเจ็บเพิ่มขึ้นเป็น 4.18 เท่า
ของคนที่ไม่ตก เมื่อตัดตัวรบกวนจากการ
หลับขณะเกิดเหตุ การนั่งบริเวณที่มีการ
ยุบตัวของตัวถังรถและการโดนชิ้นส่วนรถ
กระแทกแล้ว
- คนที่นั่งบริเวณที่มีการยุบตัวของรถมีความ
เสี่ยงที่จะมีคะแนนความรุนแรงการ
บาดเจ็บเพิ่มขึ้น 3.86 เท่า เมื่อตัดตัว
รบกวนจากการหลับขณะเกิดเหตุ การตก
เก้าอี้และการโดนชิ้นส่วนรถกระแทกแล้ว

Multivariate analysis; Coef.

134

```
. poisson ais fal4 slept dambus hit
```

Iteration 0: log likelihood = -330.60085
Iteration 1: log likelihood = -330.50745
Iteration 2: log likelihood = -330.50742

Poisson regression

Log likelihood = -330.50742

	Number of obs	=	44
	LR chi2(4)	=	540.21
	Prob > chi2	=	0.0000
	Pseudo R2	=	0.4497

ais	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
fal4	1.429914	.135469	10.56	0.000	1.1644	1.695429
slept	.1397997	.1022788	1.37	0.172	-.0606631	.3402624
dambus	1.349691	.0823353	16.39	0.000	1.188317	1.511065
hit	.0736658	.0099492	7.40	0.000	.0541657	.093166
_cons	.3906691	.1779021	2.20	0.028	.0419875	.7393508

- ผู้ที่ตกจากเก้าอี้จะมีความเสี่ยงที่จะมีค่า
รุนแรงการบาดเจ็บเพิ่มขึ้นเป็น 1.43
คะแนน เมื่อตัดตัวรบกวนจากการหลับ
ขณะเกิดเหตุ การนั่งบริเวณที่มีการยุบตัว
ของตัวถังรถและการโดนชิ้นส่วนรถ
กระแทกแล้ว
- คนที่นั่งบริเวณที่มีการยุบตัวขอรถมีความ
เสี่ยงที่จะมีคะแนนความรุนแรงการ
บาดเจ็บเพิ่มขึ้น 1.35 เมื่อตัดตัวรบกวน
จากการหลับขณะเกิดเหตุ การตกเก้าอี้
และการโดนชิ้นส่วนรถกระแทกแล้ว

Data management Poisson Regression 135

```
. use "D:\practice data sets\depress2.dta"
```

	subj	dep1	dep2	dep3	dep4	dep5	dep6	group	pre
1	1	17	18	15	17	14	15	placebo	18
2	2	26	23	18	17	12	10	placebo	27
3	3	17	14	.	.	.	.	placebo	16
4	4	14	23	17	13	12	12	placebo	17
5	5	12	10	8	4	5	5	placebo	15
6	6	19	11.54	9	8	6.82	5.05	placebo	20
7	7	13	13	9	7	8	7	placebo	16
8	8	26	27	.	.	.	.	placebo	28
9	9	26	24	19	13.94	11	9	placebo	28
10	10	9	12	15	12	13	20	placebo	25
11	11	14	.	.	.	.	.	placebo	24
12	12	19	13	14	23	15	11	placebo	16
13	13	13	22	.	.	.	.	placebo	26

	subj	dep1	dep2	dep3	dep4	dep5	dep6	group	pre	post	diff	diff2	better	ptime
1	1	17	18	15	17	14	15	placebo	18	15	3	3	0	6
2	2	26	23	18	17	12	10	placebo	27	10	17	17	1	6
3	3	17	14	.	.	.	.	placebo	16	14	2	2	0	2
4	4	14	23	17	13	12	12	placebo	17	12	5	5	0	6
5	5	12	10	8	4	5	5	placebo	15	5	10	10	1	6
6	6	19	11.54	9	8	6.82	5.05	placebo	20	5.05	14.95	14.95	1	6
7	7	13	13	9	7	8	7	placebo	16	7	9	9	0	6
8	8	26	27	.	.	.	.	placebo	28	27	1	1	0	2
9	9	26	24	19	13.94	11	9	placebo	28	9	19	19	1	6
10	10	9	12	15	12	13	20	placebo	25	20	5	5	0	6
11	11	14	.	.	.	.	.	placebo	24	14	10	10	1	1
12	12	19	13	14	23	15	11	placebo	16	11	5	5	0	6
13	13	13	22	.	.	.	.	placebo	26	22	4	4	0	2
14	14	7	13	.	.	.	.	placebo	21	13	8	8	0	2
15	15	18	.	.	.	.	.	placebo	21	18	3	3	0	1
16	16	18	.	.	.	.	.	placebo	22	18	4	4	0	1
17	17	19	13	22	12	18	13	placebo	26	13	13	13	1	6
18	18	19	7	8	2	5	6	placebo	19	6	13	13	1	6
19	19	20	18	20	17	15	13.73	placebo	22	13.73	8.27	8.27	0	6


Rate ratio / Incidence rate ratio (IRR) (1)

136

- ▶ A ratio of two incidence rates
- ▶ Used in RCT or Cohort study (with person-time data)
- ▶ Rate ratio (IRR) = $[A/TE] / [B/TU]$
- ▶ $IRR = (25/178)/(9/117) = 1.82$



	No. of sick	Person-time	Incidence rate
Exposed	A	TE	A/TE
Unexposed	B	TU	B/TU
Total	A+B	TE+TU	(A+B)/(TE+TU)

	No. of better	Person-time	Incidence rate
estrogen	25	178	0.1404= 14.04%
Placebo	9	117	0.0769= 7.69%
Total	A+B	TE+TU	(A+B)/(TE+TU)



```
. tab group better
```

group	better 0	1	Total
placebo	18	9	27
estrogen	9	25	34
Total	27	34	61



```
. total ptime, over(group)
```

Total estimation		Number of obs = 61		
	Total	Std. Err.	[95% Conf. Interval]	
c.p _{time} @group				
placebo	117	11.61895	93.75864	140.2414
estrogen	178	9.951397	158.0942	197.9058

	coef.	Std. Err.	t	P> t
	121	103.4714	-2.27	0.025
	186	105.1879	-0.91	0.365

- Poisson regression
- Negative binomial regression
- Generalized negative binomial regression
- Zero-inflated Poisson regression
- Zero-inflated negative binomial regression
- Truncated Poisson regression
- Truncated negative binomial regression
- Censored Poisson regression
- Poisson model with endogenous covariates
- Poisson model with sample selection
- Panel Poisson regression
- Panel negative binomial regression
- Multilevel Poisson regression
- Multilevel negative binomial regression
- Exact Poisson regression
- Poisson regression finite mixture model
- Negative binomial regression finite mixture model
- Truncated Poisson regression finite mixture model
- Treatment effects
- Nonparametric regression
- Lasso inferential models
- Bayesian regression

poisson - Poisson regression

Model by/it/in Weights SE/Robust Reporting Maximization

Dependent variable: diff

Independent variables: group

☐ Suppress constant term

Options

☒ Exposure variable:

☐ Offset variable:

Constraints: Manage...

OK Cancel Submit

poisson - Poisson regression

Model by/it/in Weights SE/Robust Reporting Maximization

☒ Confidence level

☐ Report coefficients (default)

☒ Report incidence-rate ratios

☐ Do not report constraints

☒ Report p-values, test statistics, and confidence intervals

☐ Suppress confidence intervals

☐ Suppress p-values and test statistics

Factor-variable reporting options Set table formats

OK Cancel Submit

137

```
. poisson diff group, irr
note: you are responsible for interpretation of noncount dep. variable

Iteration 0:  log likelihood = -218.04324
Iteration 1:  log likelihood = -218.04323

Poisson regression                                Number of obs   =          61
LR chi2(1)                                         =          51.85
Prob > chi2                                        =          0.0000
Pseudo R2                                         =          0.1063

Log likelihood = -218.04323
```

	diff	IRR	Std. Err.	z	P> z	[95% Conf. Interval]
group		1.809487	.1539536	6.97	0.000	1.53156 2.137848
_cons		7.361852	.5221697	28.15	0.000	6.406371 8.459838

Conclusion

Type of study design

ดูว่างานเราเป็นแบบไหน

- ▶ Qualitative / quantitative
- ▶ Descriptive
- ▶ Analytic ??
- ▶ Cohort/Case control/Cross-sectional

Type of data

1. ข้อมูลเราเป็นแบบไหน
Category / ordinal/ continue
Normal distribution ??
1. ตัวไหนเป็น outcome / exposure

Descriptive study

141



- ▶ Categorical Variables
 - Ratio, Proportion, Percent (%)

- ▶ Continuous Variable
 - Normal Distribution
 - Mean, SD
 - Not normal Distribution
 - Median, Range/IQR

Analytic

- ▶ Comparison
 - ▶ Categorical outcome
 - ▶ Chi-square (χ^2) test
 - ▶ Continuous Variable
 - ❖ Normal Distribution
 - ▶ t-test (2 groups) F-test/ANOVA (≥ 2 groups)
 - ❖ Not normal Distribution
 - ▶ Wilcoxon test, Mann-Whitney U test
- ▶ Association
 - ▶ Study design

Association by study design

Study design	Measure of frequency	Measure of association
Cross-sectional	Prevalence	• Prevalence ratio • Prevalence odds ratio
Case-control	Prevalence	• Odds ratio
Cohort	Incidence	• Risk ratio • Odds ratio

Regression model (Predict/ Odds ratio)

- ▶ Linear Regression
 - ❖ Y = continuous + normal distribution
- ▶ Logistic Regression
 - ❖ Y = Categorical
- ▶ Poisson Regression
 - ❖ Y = Incidence/count
- ▶ Cox's Proportional Hazard Regression
 - ❖ Y = Time to event

Y = outcome, x = exposure
 X = continuous / categorical