

# Medical statistics (QUANTITATIVE METHOD V)

หลักสูตรเวชศาสตร์ชุมชน

RACM 302

1

## สถิติ (Statistics)

- วิชาสถิติเป็นวิชาที่เกี่ยวกับวิธีการรวบรวมข้อมูล จัดการ วิเคราะห์ นำเสนอ แปลผล และหาข้อสรุปจากข้อมูล

2

## สถิติเชิงพรรณนา (Descriptive statistics)

- บรรยายและสรุปลักษณะของข้อมูล

เช่น ประชากรในชุมชนนี้ มีน้ำหนัก ส่วนสูง สัดส่วนเพศชายหญิง ระดับความดันเลือด ฯลฯ เป็นเท่าไร

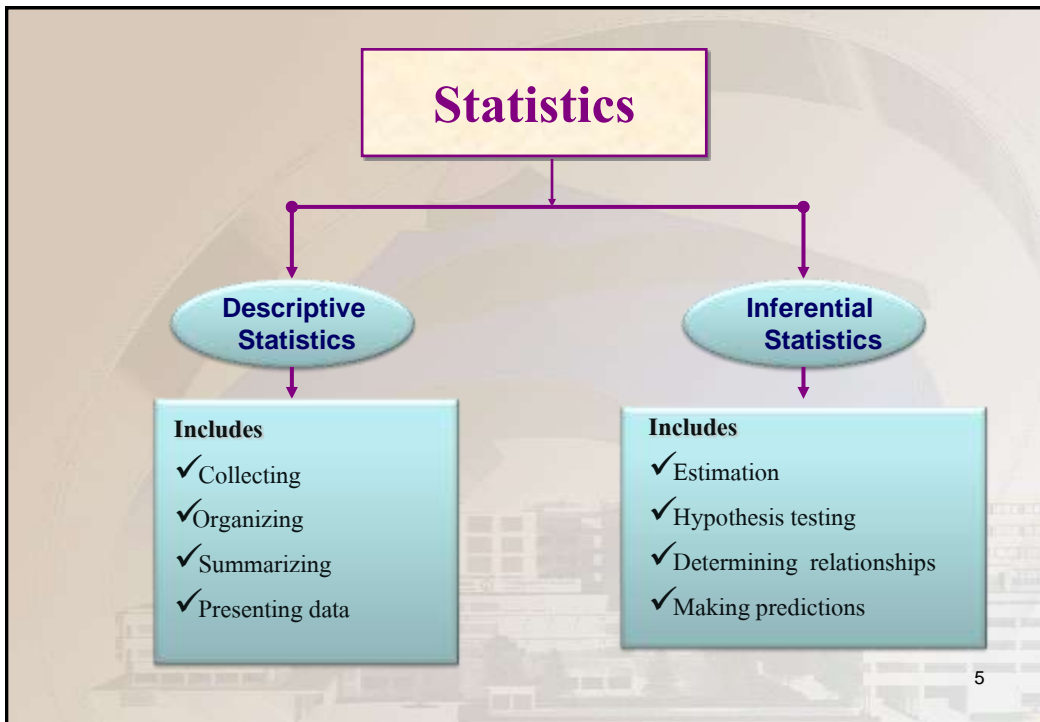
3

## สถิติเชิงอนุมาน (Inferential statistics)

- หาข้อสรุปของประชากร จากข้อมูลที่เก็บได้ในกลุ่มตัวอย่าง

เช่น สุ่มตัวอย่าง นศพ.ชาย 50 คน ได้ส่วนสูงเฉลี่ยเท่ากับ 170 ซม. เพื่อต้องการหาส่วนสูงเฉลี่ยใน นศพ.ชายทั้งหมดว่า เป็นเท่าไร

4



## Parameter & Statistic

- **Parameter** คือค่าของประชากรทั้งหมด
- **Statistic** คือค่าที่หาได้ในกลุ่มตัวอย่าง

6

## ตัวแปร (Variable)

- หมายถึงลักษณะ (characteristic) ของข้อมูล เช่น อายุ เพศ น้ำหนัก ระดับน้ำตาล ความดันเลือด การหายหรือตายจากโรค ฯลฯ

7

## ตัวแปร (variable)

- Qualitative (Discrete)
  - nominal
  - ordinal
- Quantitative (continuous)
  - interval
  - ratio

8

## Scale of measurement

- **Nominal variable** (nominal = name) :

บอกลักษณะ เช่น blood group, sex, cause of death

- **Ordinal variable** (ordinal = order) :

บอกลำดับ เช่น severity of disease

(mild, moderate, severe), การสูบบุหรี่

(<= 10 มวน, 11-20 มวน, >20 มวนต่อวัน)

9

## Scale of measurement

- **Ratio variable** :

วัดต่อเนื่องได้ถึงทศนิยมไม่รู้จบ มีศูนย์ที่แท้จริง  
เช่น น้ำหนัก ส่วนสูง ระดับไขมัน อองศาเคลวิน

- **Interval variable** :

วัดต่อเนื่องได้ แต่มีศูนย์ที่ไม่แท้จริง เช่น อุณหภูมิ  
องศาเซลเซียส

10

## Descriptive Statistics

- การวัดแนวโน้มเข้าสู่ส่วนกลาง  
(Measure of central tendency)
  - เป็นการบอกค่ากลางของชุดข้อมูลว่าเป็นเท่าใด
  - ตัวชี้วัดที่นิยมใช้ได้แก่ Mean, Median และ Mode

11

## คำจำกัดความ

Mean = ค่าเฉลี่ยของชุดข้อมูล  $\bar{x} = \frac{\sum x_i}{n}$

Median = ค่าที่อยู่กึ่งกลางของข้อมูลที่เรียงลำดับ

Mode = ค่าที่มีความถี่ (พบ) มากที่สุด

12

## การวัดความแปรปรวน (Measure of variability)

- เป็นการบอกถึงการกระจายตัวของชุดข้อมูลว่ามีมากน้อยเพียงไร
- ตัวชี้วัดที่นิยมใช้ได้แก่ Range, Standard deviation, Variance และ Interquartile range

13

## คำจำกัดความ

Range = ค่ามากที่สุด ลบ ค่าน้อยสุด

Variance = 
$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

S.D. = Square root ของ variance

Interquartile range =  $Q_3 - Q_1$  หรือ  $P_{75} - P_{25}$

14

## Coefficient of Variation (C.V.)

ตาราง เปรียบเทียบส่วนสูง ของ นักเรียนชั้นประถมศึกษาปีที่ 6  
และมัธยมศึกษาปีที่ 6

	ประถมศึกษาปีที่ 6	มัธยมศึกษาปีที่ 6
อายุ (เฉลี่ย)	11	17
ส่วนสูง (เฉลี่ย)	140	170
<b>S.D.</b>	10	10

15

## Coefficient of Variation (C.V.)

- สรุปลำไม่ได้
- น่าจะเทียบความแปรปรวนกับค่าเฉลี่ย

$$C.V. = \frac{S.D.}{\bar{X}} \times 100\%$$


$$\therefore C.V. \text{ ประถมปีที่ 6} = \frac{10}{140} \times 100\% = 7.1\%$$

$$C.V. \text{ มัธยมปีที่ 6} = \frac{10}{170} \times 100\% = 5.9\%$$

16

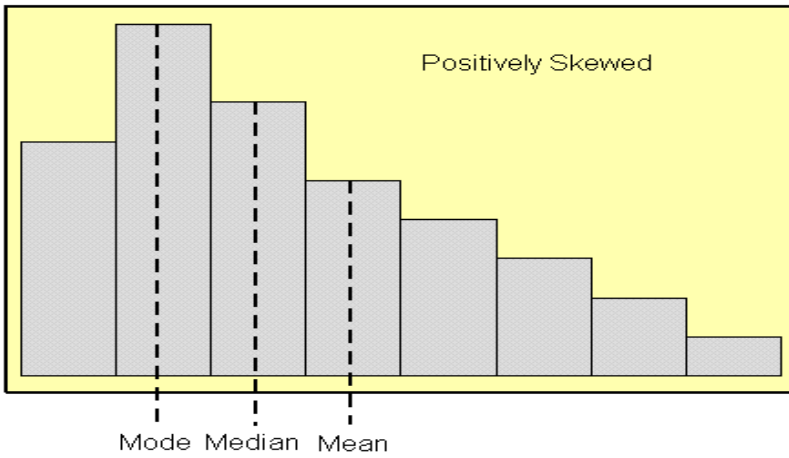


## Distribution




17

## Distribution




18

## Distribution



19

## การแปลผลค่า S.D.



$(\bar{x} - s, \bar{x} + s)$  contains approximately 68% of the measurements

$(\bar{x} - 2s, \bar{x} + 2s)$  contains approximately 95% of the measurements

$(\bar{x} - 3s, \bar{x} + 3s)$  contains virtually all of the measurements

20

## Inferential statistics

- **Estimation** เป็นการประมาณค่าในประชากรจากข้อมูลในกลุ่มตัวอย่าง เช่น ความดันเลือดสูงในกลุ่มประชาชนอายุตั้งแต่ 40 ปีขึ้นไปในชุมชนเป็นเท่าไร

21

## Estimation

- การศึกษาในกลุ่มตัวอย่างย่อมได้ค่าในกลุ่มตัวอย่าง (sample estimate) จึงต้องหาค่าในประชากร (population estimate) ว่าเป็นเท่าใด
- วิธีการหาค่า population estimate ได้แก่ การหาค่า **confidence interval**

22

## การแปลผล confidence interval

Prevalence ของ HT ในชุมชน ก. เท่ากับ 30%  
(95% C.I. = 27%-33%) แปลผลว่า

Prevalence ของ HT ในชุมชน ก. น่าจะมีค่าอยู่  
ระหว่าง 27% - 33% ด้วยความเชื่อมั่น 95%

Sample estimate = 30%

Population estimate = 27% – 33%

23

## Inferential statistics

- Hypothesis testing เป็นการพิสูจน์สมมติฐานว่ามี  
ความสัมพันธ์ระหว่างตัวแปรหรือไม่  
เช่น มีความแตกต่างกันระหว่างกลุ่มหญิงและชาย  
หรือไม่ในการมีภาวะความดันเลือดสูง

24

## Hypothesis testing

- การศึกษาหรือวิจัยมักจะมีการตั้งสมมติฐานเพื่อทดสอบ
- สมมติฐานที่ตั้งไว้โดยทั่วไปจะมี 2 สมมติฐาน ได้แก่
  1. Null hypothesis หรือสมมติฐานของความไม่แตกต่าง เช่น ไม่มีความแตกต่างของ ความชุกสำหรับภาวะ HT ระหว่างประชากรชายและหญิง ( difference = 0)
  2. Alternative hypothesis หรือสมมติฐานทางเลือก เช่น มีความแตกต่างของ ความชุกสำหรับภาวะ HT ระหว่าง ประชากรชายและหญิง (difference ไม่เท่ากับ 0)

25

## ขั้นตอนของ hypothesis testing

1. ตั้งสมมติฐาน
2. กำหนดเกณฑ์ต่างๆ เช่น ระดับนัยสำคัญ
3. เก็บข้อมูลจากกลุ่มตัวอย่าง
4. หาค่าสถิติ (test statistics)
5. คำนวณค่า p (probability value)
6. สรุปหรือปฏิเสธสมมติฐาน

26

## ขั้นตอนของ hypothesis testing

1. ตั้งสมมติฐาน
2. กำหนดเกณฑ์ต่างๆ เช่น ระดับนัยสำคัญ
3. เก็บข้อมูลจากกลุ่มตัวอย่าง
4. หาค่าสถิติ (test statistics)
5. คำนวณค่า p (probability value)
6. สรุปหรือปฏิเสธสมมติฐาน

27

ตารางเปรียบเทียบผลการตรวจคัดกรองความดันเลือดใน  
กลุ่มชาย-หญิงอายุตั้งแต่ 40 ปีขึ้นไป  
(observed table)

เพศ	ความดันเลือดสูง	ความดันเลือดปกติ	รวม
ชาย	9	41	50
หญิง	21	29	50
รวม	30	70	100

**Chi-Square**

**P-value**

28

$$\sum (o - e) = 0$$

$$Chi - Square = \sum \frac{(O - E)^2}{E}$$

**Chi-Square = 3.84    p-value 0.05**

**degree of freedom=1**

29

ตารางเปรียบเทียบผลการตรวจคัดกรองความดันเลือด  
ในกลุ่มชาย-หญิงอายุตั้งแต่ 40 ปีขึ้นไป  
(expected table)

เพศ	ความดันเลือดสูง		ความดันเลือดปกติ	รวม
ชาย	15	a	b	35
หญิง	15	c	d	35
รวม	30		70	100

**Chi-Square**

**P-value**

30

ตารางเปรียบเทียบผลการตรวจคัดกรองความดันเลือด  
ในกลุ่มชาย-หญิงอายุตั้งแต่ 40 ปีขึ้นไป

เพศ	ความดันเลือดสูง	ความดันเลือดปกติ	รวม
ชาย	9	41	50
หญิง	21	29	50
รวม	30	70	100

**Chi-Square 6.86**

**P-value 0.0088**

31

## การแปลผล hypothesis testing

- ระดับนัยสำคัญตั้งไว้ที่ระดับใด  
.05 หรือ .01 หรือ .1
- ค่า p ได้เท่าไร  
น้อยกว่าระดับนัยสำคัญที่ตั้งไว้หรือไม่
- ถ้าน้อยกว่า แสดงว่ามีนัยสำคัญทางสถิติ

32



## การแปลผล hypothesis testing

- ถ้าเท่ากับหรือมากกว่า ก็ไม่มีนัยสำคัญทางสถิติ
- P-value คือ โอกาสที่จะได้ค่าสถิติตามที่พบในกลุ่มตัวอย่างหรือมากกว่าถ้า null hypothesis เป็นความจริง

33

## การแปลผล

ถ้าความชุกของความดันเลือดสูงในเพศชายและหญิงไม่แตกต่างกัน โอกาสจะเห็นความแตกต่างเช่นนี้หรือมากกว่าโดยบังเอิญมีค่า น้อยกว่า 0.0088 หรือ .88%

เราจึงเลือกสรุปว่าแตกต่างกัน

เพราะโอกาสสรุปผิดมีน้อยกว่า 5%

34

## โอกาสสรุปผิด

การศึกษาหรือวิจัยมีโอกาสสรุปผิดได้ 2 ทาง

- สรุปผลว่ามีความแตกต่างในขณะที่ความจริงในประชากรไม่มี เรียกว่า เกิด *Type I (alpha) error*
- สรุปผลว่าไม่มีความแตกต่างในขณะที่ความจริงในประชากรมี เรียกว่า เกิด *Type II (beta) error*

35

## True Reality

		Ha	Ho
Your Decision	Ha	correct conclusion	Type I error
	Ho	Type II error	correct conclusion

36

## Power & Sample size

- กรณีไม่พบนัยสำคัญทางสถิติ ต้องสงสัยว่าการศึกษานี้มี power เพียงพอหรือไม่
- Power คืออำนาจการตรวจสอบความแตกต่างที่อาจมีอยู่จริงในประชากร
- Power มีค่าเท่ากับ  $1 - \beta$  ( $1 - \text{type II error}$ )
- Power จะขึ้นอยู่กับ Sample size เป็นหลัก

37

## วิธีการทางสถิติที่ใช้บ่อย ในการทดสอบสมมติฐาน

1. t-test ทดสอบความแตกต่างของ continuous variable ระหว่าง 2 กลุ่ม
2. F-test ทดสอบความแตกต่างของ continuous variable ระหว่าง 3 กลุ่มขึ้นไป
3. Chi-square ทดสอบความสัมพันธ์ของ discrete variable ตั้งแต่ 2 กลุ่มขึ้นไป
4. Correlation ทดสอบความสัมพันธ์ระหว่างตัวแปรที่เป็น continuous variable
5. Regression ทำนาย (predict) ค่า dependent variable จากค่า independent variables

38

## ตัวอย่าง t-test

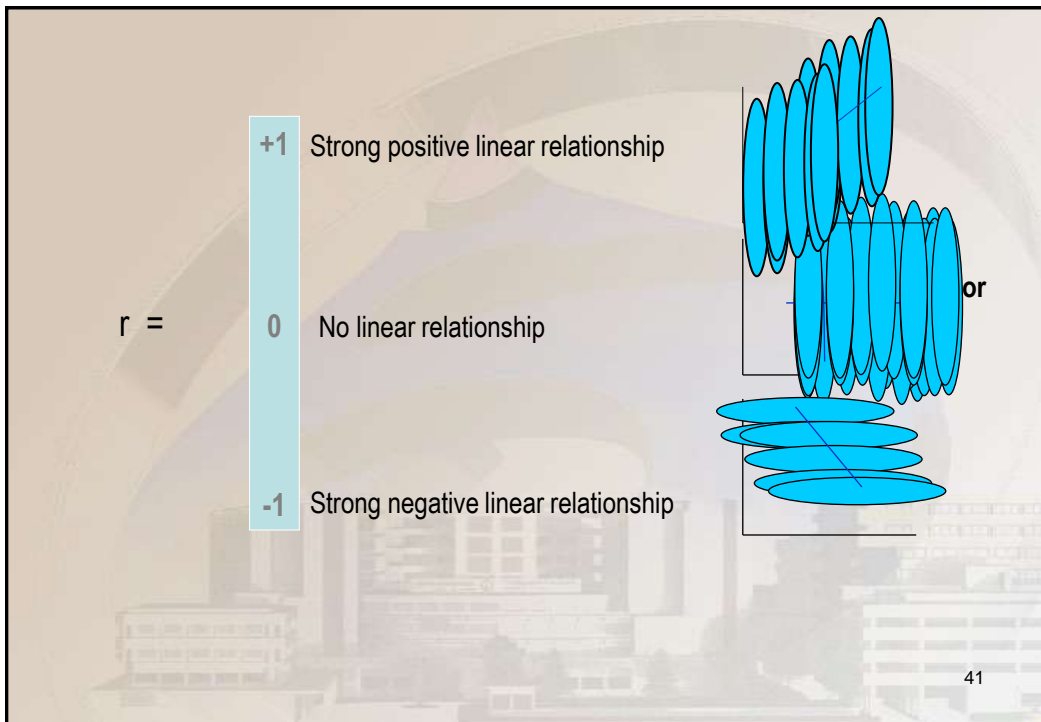
- ค่า uric acid ในเด็ก mongolism แตกต่างจากเด็กปกติหรือไม่
- Null hypothesis : ค่า uric acid ในเด็ก mongolism เท่ากับเด็กปกติ
- กำหนดระดับนัยสำคัญที่ .05
- เก็บข้อมูลในกลุ่มตัวอย่างเด็กทั้งสองกลุ่ม
- นำข้อมูลดิบเข้าโปรแกรมคอมพิวเตอร์โดยใช้วิธีการทางสถิติ t-test
- ผล : ค่า p-value = 0.02 จึงปฏิเสธ null hypothesis
- สรุปผลว่า ระดับ uric acid ในเด็กทั้งสองกลุ่มแตกต่างกัน

39

## ตัวอย่าง correlation analysis

- ค่า FBS สัมพันธ์กับค่า HbA<sub>1c</sub> หรือไม่ในผู้ป่วยเบาหวาน
- Null hypothesis : ค่า FBS ไม่สัมพันธ์กับค่า HbA<sub>1c</sub> ในผู้ป่วยเบาหวาน
- กำหนดระดับนัยสำคัญที่ .05
- เก็บข้อมูลค่า FBS และค่า HbA<sub>1c</sub> ในกลุ่มตัวอย่างผู้ป่วยเบาหวาน
- นำข้อมูลดิบเข้าโปรแกรมคอมพิวเตอร์โดยใช้วิธีการทางสถิติ correlation
- ผล : ค่า r = 0.8 ค่า p-value = 0.03 จึงปฏิเสธ null hypothesis
- สรุปผลว่า ค่า FBS กับค่า HbA<sub>1c</sub> มีความสัมพันธ์กันในระดับดี

40



## ทำไมต้อง Confidence interval

- ถ้าอยากรู้ว่าความสูงเฉลี่ยของนักเรียนชายมัธยมปีที่ 6 ทั่วประเทศ ปีการศึกษา 2550 มีค่าเท่าไร ? ในอดีตเคยมีการศึกษาในปี การศึกษา 2530 มีค่า **population mean=165 ซม. population standard deviation 10 ซม.** และความสูงของนักเรียนชายมัธยมปีที่ 6 มีการกระจายแบบโค้งปกติ


43

## Sample estimation

- ถ้าความสูงเฉลี่ยของนักเรียนชายมัธยมปีที่ 6 ปีการศึกษา 2553 จำนวน 100 คนที่ได้จากการสุ่มตัวอย่าง มีค่า **sample mean = 170 ซม. S.D.= 8 ซม.** ท่านคิดว่าค่า **population mean** มีค่าเท่าไร

44

## distribution of sample means



$$\pm 1.96\sigma_{\bar{x}} = 95\%$$

45

## Population estimation

95% confidence interval  $\mu$

$$\begin{aligned}
 &= \bar{x} \pm 1.96\sigma_{\bar{x}} \\
 &= 170 \pm 1.96 * \frac{10}{\sqrt{100}} \\
 &= 168-172 \text{ ဖ.မ.}
 \end{aligned}$$

46

## 95% CI สำหรับค่า Prevalence

- ถ้าอยากรู้ว่านักเรียนแพทย์ชั้นปี3 ทั่วประเทศเลือก ส.ส.ระบบ สัดส่วนสำหรับ พรรค ก. ร้อยละเท่าไร ?
- ถ้าทำการสุ่มนักเรียนแพทย์ชั้นปี3 ทั่วประเทศ มา 100 คน พบว่า เลือกพรรค ก. 40% ซึ่งเป็น sample estimate
- การหา Population estimate ทำได้โดยใช้สูตร

$$95\% \text{ CI ของ Prevalence (P)} = p \pm 1.96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}$$

47

## 95% CI สำหรับค่า Prevalence

- 95% CI สำหรับการเลือกพรรค ก. มีค่า

$$= 0.4 \pm 1.96 \frac{\sqrt{0.4 * (1 - 0.4)}}{\sqrt{100}}$$

$$= ( 0.304 - 0.496 )$$

48



## การประยุกต์ค่า 95%CI สำหรับ sample size

จากสูตร 95% CI ของ P =  $p \pm 1.96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}$

$$\text{interval} = \pm 1.96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}$$

$$\pm d = \pm 1.96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}$$

$$n = Z_{(1-\alpha/2)}^2 * \frac{p(1-p)}{d^2}$$