

# CS381: Numerical Computation & Softwares


## Linear Least Square Problems

Jakramate Bootkrajang

Department of Computer Science  
Chiang Mai University


# Motivation

- ย้อนกลับไปยังปัญหาการประมาณค่าฟังก์ชัน ณ จุดที่ไม่มีข้อมูล
- ข้อมูลที่มีอยู่ในรูป  $(x_i, y_i = f(x_i))$ ,  $i = 0, \dots, N$




- วิธีที่สามารถนำมาใช้แก้ปัญหานี้ได้คือการทำ interpolation แล้วประมาณ  $y_i$  ณ จุด  $x$  ที่สนใจ


- Interpolation มีสมมติฐานว่าฟังก์ชัน  $f(x)$  แสดงได้ด้วยพหุนามดีกรี  $N - 1$  ซึ่งอาจถูกหรือผิดก็ได้
- บางครั้งพหุนามที่หาได้อาจมีความซับซ้อนมากกว่า ความสัมพันธ์ของ  $x_i$  และ  $y_i$  จริง



# Motivation

- นอกจากการสมมติว่า  $f()$  มีลักษณะเป็นพหุนามแล้ว เราสามารถตั้งสมมติฐานว่าฟังก์ชัน  $f()$  มีลักษณะเป็นเชิงเส้นได้
- แนนอนว่า การอธิบายข้อมูล  $(x_i, y_i = f(x_i))$ ,  $i = 0, \dots, N$  ด้วยฟังก์ชันเชิงเส้นมีข้อจำกัด คือ เป็นการยากที่เส้นตรงดังกล่าวจะลากผ่านทุกจุดข้อมูล





- ระยะห่างระหว่างค่าประมาณกับค่าจริง (เส้นสีเขียว) ของค่า  $x_i$  ใด ถือว่าเป็น error ที่เกิดขึ้นจากข้อจำกัดของฟังก์ชันเชิงเส้น (mathematical error)
- เป้าหมายของการอธิบายชุดข้อมูลด้วยฟังก์ชันเชิงเส้นคือการหาฟังก์ชัน  $f(x) = ax$  ที่ทำให้เกิดค่า error รวมบนชุดข้อมูลน้อยที่สุด
- ส่วนมากแล้ว เรามักให้ค่า error รวมแทนด้วยผลรวมของค่าความคาดเคลื่อนยกกำลังสอง

# Sum of square error

- ค่าความคาดเคลื่อนของการประมาณ  $y_i$  ของ  $x_i$  แต่ละตัวสามารถคิดจาก

$$\epsilon_i = y_i - f(x_i) \quad (1)$$

$$= y_i - ax_i \quad (2)$$

- เนื่องจากค่าประมาณ ( $ax_i$ ) อาจมากกว่าหรือน้อยกว่า  $y_i$  ทำให้  $\epsilon_i$  เป็นได้ทั้งบวกและลบ เมื่อนำ  $\epsilon_i$  มาบวกกันอาจเกิดการหักล้างกัน

- จึงทำการแปลงค่าความคาดเคลื่อนให้เป็นบวกเหมือนกันทั้งหมดโดยการยกกำลังสอง

$$\epsilon_i = (y_i - ax_i)^2 \quad (3)$$

- หากรวมค่าความคาดเคลื่อนของทุกๆ  $x_i$  เข้าด้วยกันจะได้ว่า

$$\epsilon = \sum_{i=0}^N (y_i - ax_i)^2 \quad (4)$$

- เราสามารถเขียนสมการความคาดเคลื่อนกำลังสองรวมในรูปของเมทริกซ์ได้

$$\epsilon = \|X\vec{a} - Y\|_2^2 \quad (5)$$

- $X$  คือเมทริกซ์ของข้อมูล มีขนาด  $N$  คูณ  $M$  ( $N$  จำนวนข้อมูล  $M$  มิติของข้อมูล)
- $Y$  คือเมทริกซ์ของ response
- $\vec{a}$  คือเวกเตอร์สัมประสิทธิ์ของฟังก์ชันเชิงเส้นที่ต้องตามหา

## In matrix form: Example

- กำหนดชุดข้อมูล  $\{(3, 14), (2, 13), (5, 19)\}$

$$X = \begin{bmatrix} 3 \\ 2 \\ 5 \end{bmatrix}, \vec{a} = [a_1], Y = \begin{bmatrix} 14 \\ 13 \\ 19 \end{bmatrix} \quad (6)$$

- หรือ

$$X = \begin{bmatrix} 3 & 2 \\ 2 & 1 \\ 5 & 4 \end{bmatrix}, \vec{a} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}, Y = \begin{bmatrix} 3.3 \\ 1.5 \\ 7.9 \end{bmatrix} \quad (7)$$

- สังเกตว่าปัญหาระบบสมการเชิงเส้นที่ไม่มีคำตอบ สามารถมองเป็นปัญหา least square ได้



## In matrix form: Example


- เพิ่มตัวอย่าง regression จริง

# Linear Least Square

- เป้าหมายคือการหา  $\vec{a}$  ที่ทำให้ค่า error มีค่าน้อยที่สุด โดยการ minimize ฟังก์ชันจุดประสงค์ (objective function)

$$L = \min_{\vec{a}} \|X\vec{a} - Y\|_2^2 \quad (8)$$

- ฟังก์ชันจุดประสงค์ดังกล่าวเป็นฟังก์ชันแบบรูปเว้า (convex function) ที่มีจุดต่ำสุด



## Where the best $\vec{a}$ is ?

- จากวิชา calculus เราทราบว่าจุดต่ำสุดของฟังก์ชันจุดประสงค์ดังกล่าวคือจุดที่อนุพันธ์ของฟังก์ชันมีค่าเท่ากับ 0 หรือ

$$\frac{\partial L}{\partial \vec{a}} = \frac{\partial \|X\vec{a} - Y\|_2^2}{\partial \vec{a}} \quad (9)$$

$$= 2(X\vec{a} - Y)X \quad (10)$$

- ต่อไปหาค่า  $\vec{a}$  เมื่อสมการที่ (10) มีค่าเท่ากับ 0

$$(X\vec{a} - Y)X = 0 \quad (11)$$

$$X^T X\vec{a} - X^T Y = 0 \quad (12)$$

$$\vec{a} = (X^T X)^{-1} X^T Y \quad (13)$$

## Computing $\vec{a}$ is expensive

$$\vec{a} = (X^T X)^{-1} X^T Y$$

- Closed-form solution ของ  $\vec{a}$  มีการหา inverse ของเมทริกซ์  $(X^T X)$  ซึ่งช้า หาก  $X$  มีจำนวน column มาก
- ในทางปฏิบัติคือกรณีที่ข้อมูลมี feature มาก
- การหาคำตอบของ least square problem อาจพิจารณาใช้วิธีอื่นที่เลี่ยงการคำนวณ inverse โดยตรง

$$\vec{a} = (X^T X)^{-1} X^T Y$$

- แนวทางหนึ่งคือการพยายามแยกส่วน (decompose) เมทริกซ์  $(X^T X)$  ให้อยู่ในรูปของการคูณกันของเมทริกซ์อื่นที่เลี่ยงการหา inverse
- Cholesky decomposition ทำการ decompose  $(X^T X) = R^T R$
- Singular Value Decomposition ทำการ decompose  $(X^T X) = U \Sigma V^T$

$$X^T X = R^T R$$

- Cholesky decomposition ทำการ decompose  $(X^T X) = R^T R$
- Example

$$\begin{bmatrix} 4 & 12 & -16 \\ 12 & 37 & -43 \\ -16 & -43 & 98 \end{bmatrix} = \begin{bmatrix} 2 & 0 & 0 \\ 6 & 1 & 0 \\ -8 & 5 & 3 \end{bmatrix} \times \begin{bmatrix} 2 & 6 & -8 \\ 0 & 1 & 5 \\ 0 & 0 & 3 \end{bmatrix} \quad (14)$$

# Algorithm for Cholesky decomposition

- The Cholesky–Banachiewicz / Cholesky–Crout algorithms คำนวณย้อนกลับ

$$A = R^T R = \begin{bmatrix} R_{11} & 0 & 0 \\ R_{21} & R_{22} & 0 \\ R_{31} & R_{32} & R_{33} \end{bmatrix} \times \begin{bmatrix} R_{11} & R_{21} & R_{31} \\ 0 & R_{22} & R_{32} \\ 0 & 0 & R_{33} \end{bmatrix} \quad (15)$$

$$= \begin{bmatrix} R_{11}^2 & \dots & \text{symmetric} \\ R_{21}R_{11} & R_{21}^2 + R_{22}^2 & \dots \\ R_{31}R_{11} & R_{31}R_{21} + R_{32}R_{22} & R_{11}^2 + R_{22}^2 + R_{33}^2 \end{bmatrix} \quad (16)$$

- ตั้งนั้นแล้ว

$$R = \begin{bmatrix} \sqrt{A_{11}} & 0 & 0 \\ A_{21}/R_{11} & \sqrt{A_{22} - R_{21}^2} & 0 \\ A_{31}/R_{11} & (A_{32} - R_{31}R_{21})/R_{22} & \sqrt{A_{33} - R_{31}^2 - R_{32}^2} \end{bmatrix} \quad (17)$$

# The patterns emerged

- สังเกตรูปแบบของพจน์ต่างๆ

$$R = \begin{bmatrix} \sqrt{A_{11}} & 0 & 0 \\ A_{21}/R_{11} & \sqrt{A_{22} - R_{21}^2} & 0 \\ A_{31}/R_{11} & (A_{32} - R_{31}R_{21})/R_{22} & \sqrt{A_{33} - R_{31}^2 - R_{32}^2} \end{bmatrix} \quad (18)$$

- Pattern คือ

$$L_{jj} = \sqrt{A_{jj} - \sum_{k=1}^{j-1} L_{jk}^2} \quad (19)$$

$$L_{ij} = \frac{1}{L_{jj}} \left( A_{ij} - \sum_{k=1}^{j-1} L_{ik}L_{jk} \right) \text{ for } i > j \quad (20)$$



$$X^T X \vec{\alpha} = X^T Y \quad (21)$$

- 1 Compute  $X^T X$  and  $X^T Y$
- 2 Factorise  $X^T X \rightarrow R^T R$
- 3 Solve lower triangular system  $R^T w = X^T Y$  for  $w$
- 4 Solve upper triangular system  $R \vec{\alpha} = w$  for  $\vec{\alpha}$

Once we found  $\vec{\alpha}$

- เราสามารถใช้ในการทำนายค่า  $y$  ของ  $x$  ที่ไม่เคยเจอมาก่อน
- โดย  $\hat{y} = x\vec{\alpha}$

- Numerical Linear Algebra by Greg Fasshauer

[http://www.math.iit.edu/~fass/477577\\_Chapter\\_5.pdf](http://www.math.iit.edu/~fass/477577_Chapter_5.pdf)