


* 달라 보이지만 등방성 vector spaces
 갖고 있으면 Data를 더 추가해도
 y를 더 잘 설명할 수 없다.




Regression Residual.

$$\hat{\varepsilon} = (I - H)\varepsilon, H = X(X'X)^{-1}X'$$

$$\hat{\beta} = (X'X)^{-1}X'y$$

$$\approx \frac{\text{Cov}(X, y)}{\text{Var}(X)}$$

: 상관 관계
 → 내 Data의 공분산(2nd moment, variance)로
 y의 공분산을 얼마나 설명할지 보겠다는 것.



β를 잘못 추정
 Mis-specification.

Gauss Markov Theorem.

A1: $r(X) = k$, $X: S \times k$ (full-rank)


A2: $y = X\beta + \varepsilon$, $E(\varepsilon) = 0$ (Linear Relation)

A3: X are unrelated wrt ε


$E(\varepsilon|X) = 0$ or $E(\varepsilon_t | x_t) = 0$.

A4: $E(\varepsilon\varepsilon') = \sigma^2 I$, ε iid

→ 개지면 어떻게 될까?



A5: $\varepsilon \sim \text{iid } N(0, \sigma^2 I)$



: X에 따라 패턴은 따르지 않고
 다만 겹들처럼 Random으로
 0은 중심으로 있어야 한다.

* A1-A4 만족.

Linear Operator 공에서
 OLS가 BLUE.

A5까지 만족하면 BLUE.

Standardization.

: Scale Issue 제거

$$\varepsilon \rightarrow \frac{\varepsilon}{\sigma} \sim N$$

(Studentizing)

$$\hat{\varepsilon} \rightarrow \frac{\hat{\varepsilon}}{\hat{\sigma}} \sim t$$

검정 분포는
 가령으로 함.

RANSAC

Re-sample를 통해서 Outlier
 제거와 비슷한 효과를 얻었다는 것.

Mis-specification

ex) Anscombe's Quartet

Q. 내 모델이 다른 data set에서도
 비슷한 performance를 보일까?

Outliers

: Model을 망칠 수도 있다 (Mis-specification)

Data를 다루기 위한 객관적인 기준으로

leverage of point, Cook's distance가 사용됨.

'Distribution'

Outlier에 영향 많이 받는 분포.

→ Normal > Laplace > Cauchy > t-dist

Optimization


: LSE, LAD,
 Huber, Bisquare.

* kernel의 종류가 중요하게
 아닌 optimization을 잘하는
 게 중요 (error가 적어야 함)

Robustness

Advanced Regression: Sparsity

Data Term + Regularization Term.



Ridge / Lasso

Bayesian

$$p(\beta | X, y) \propto p(\beta) p(X, y | \beta)$$


$$\ln p(\beta | X, y) \propto \ln p(\beta) + \ln p(X, y | \beta)$$

우리의 가정을 나타내는 부분. Regularization이란

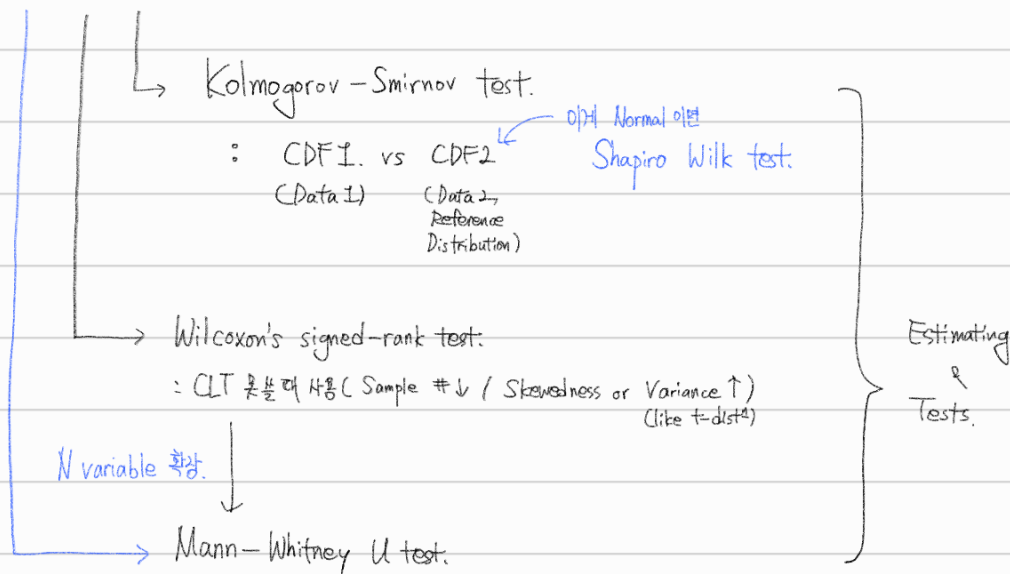
같이 설명하는 이유는 Data Dist에 맞게 설명해야 하기 때문.

Normal → 정규 분포에 맞는 regularization: Ridge } 이 분포에서 크게 벗어난 이상치들
 Laplace → Laplace에 ... : Lasso } 들어갔다는 것.

Generalized Linear Model (for real world)



Nonparametric statistics and Model selection.



Resampling Based Methods

ex) Chicago Teaching Scandal.

→ Permutation Tests.


→ Bootstrap

★ : Data를 여러 번 Resample 하면서 Variance를 보는 거?

여러 개의 distribution이 섞였을 때, 단순히 하나의 분산을 보면 잘못된 거기 때문에 일부를 여러 번 보면서 distribution이 몇 개가 있는지 각각의 분산은 어느 정도인지 보겠다는 것.
→ 보거나 Data 하나의 분산을 계산하기 위해서가 아냐.

* Model Selection.

: 가성비를 보라?



Assignment

Question 4.

- Scale Issue: 결국 X 와 Y 를 설명하기 위해서는 percent, ratio로 설명한다는 것 이해하기.

↳ $y=kx$ 로 값이 곱쳐져 있는 상황에서 $X_y = 54,500$ 으로 변해도 상관 없다. $\hat{\mu}_y$ 이 변해서 조정되기 때문이다.

- Logarithm? Scale을 줄여 Data 간 편차를 줄여 준다. → Skewness ↓ Kurtosis ↓ → 복잡한 계산 하지 말고 쉬운 계산 하자!

Question 5.


- 변수를 추가했을 때 유의미한 변화가 있을까? Model Selection을 다시 보자.

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \rightarrow R^2_{adj} = 1 - \frac{RSS / (n - p)}{TSS / (n - 1)}$$

: 변수를 추가해서 RSS가 크게 감소하는 것이 아니라면 큰 의미가 없다는 것.

- 왜 $R^2 = 1.0$ 일 때 예측값에 대한 걱정을 해야 할까?

ex)



이어서 Machine Learning은 왜 변수를 못 구할까? 모든 sample들을

이어서 만든 머신러닝 모델이 피팅선이라고 생각하자. 오차가 많다.

있더라도 매우 작아 유의미한 분산 X . (그런 X 값에 따라 달라져야 함)



t, z tests 불가.



우리의 model에 대한 검증 및 관리 X .



Ocum's razor 측면에서 Data에 따라 매번 새로 계산해야 하는 모델 보단

(머신러닝)

단순히 검증하기 추가 / 제거가 쉬운 Regression 선호.

* 머신러닝 모델은 오차를 계산 과정에 반영해

Bias를 거의 0으로 만든다.

→ 머신러닝은 Data가 거의 그대로 반복되거나 분산이 많은 (Random이 아닌) 분야에서 쓰여야 한다.

* Random이기에 당연히 μ 를 중심으로 다양한 Data가 나올 것이다.

But model은 \hat{y} 로 고정된 값이므로 μ 로 예측할 때 보다 편차가 더 커질 것.

QnA. $A3Rru$ or $A3Rmi \rightarrow$ Unbiased, Consistent :

$$A3Rmi \ E[\epsilon_t|X] = 0 \forall t \rightarrow E[\hat{\beta}] = E[(X'X)^{-1}X'y]$$

$$= E[(X'X)^{-1}X'X\beta] + E[(X'X)^{-1}X'\epsilon]$$

$$= \beta + E[E[(X'X)^{-1}X'\epsilon|X]]$$

$$= \beta + E[(X'X)^{-1}X'E(\epsilon|X)]$$

$$= \beta$$

$$E[E[(X'X)^{-1}X'\epsilon|X]]$$

$$= E[(X'X)^{-1}X'E(\epsilon|x_1, x_2, \dots, x_s)]$$

$\neq 0 \rightarrow$ Column.

Because Same Row 일 때만 0이라서.

$$(E[\epsilon_t|x_{1t}, x_{2t}, \dots, x_{st}] = 0.)$$

$$E[X'\epsilon] = 0$$

$$A3Rru \ E[\epsilon_t|x_s] = 0 \text{ if } t=s.$$

t번째 원소.

* plim : 확률 변수의 분리를 sample을 늘려가며 보는 것.

$E()$: 모든 가능성의 확률로 고려한 평균 (평균).

$$\text{Consistency : } \underset{\substack{\text{확률 변수} \\ \text{Sample \#} \uparrow}}{\text{plim}} \hat{\beta} = \text{plim } (X'X)^{-1}X'y$$

$$= \beta + \text{plim } (X'X)^{-1}X'\epsilon$$

$$= \beta + \text{plim} \left(\frac{X'X}{n} \right)^{-1} \frac{X'\epsilon}{n}$$

$$= \beta + \text{Var}(X)^{-1} \text{Cov}(X, \epsilon)$$

$$\underbrace{E(X'\epsilon)}_{=0} - \underbrace{E(X')E(\epsilon)}_{=0}$$