

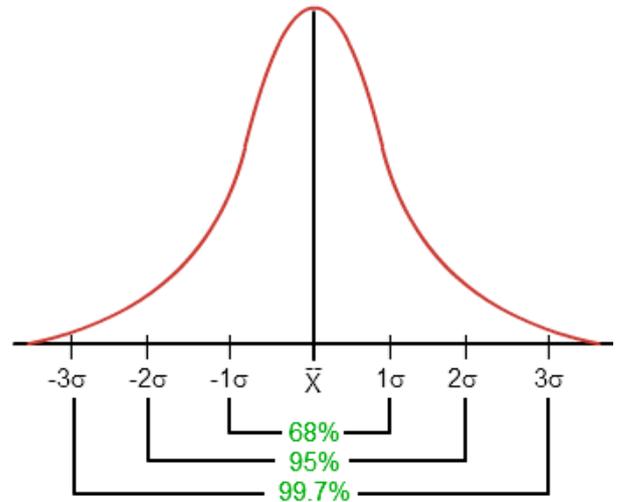
주요법칙

실증적 규칙

평균  $\mu$ , 표준편차  $\sigma$ 인 확률분포함수가 좌우 대칭인 벨 모양인 경우 다음이 성립한다.

$$P(|X - \mu| \leq k\sigma) \approx \alpha$$

- $k = 1$  : 평균을 중심으로  $\pm 1$  표준편차 구간에는 적어도 68% 데이터가 포함되어 있음
- $k = 2$  : 평균을 중심으로  $\pm 2$  표준편차 구간에는 적어도 95% 데이터가 포함되어 있음
- $k = 3$  : 평균을 중심으로  $\pm 3$  표준편차 구간에는 적어도 99.8%(대부분) 데이터가 포함되어 있음
- 만약  $k = 6$ 인 경우, 6시그마 품질, 100만개 중 2개만 범위 밖으로 나간다. 불량

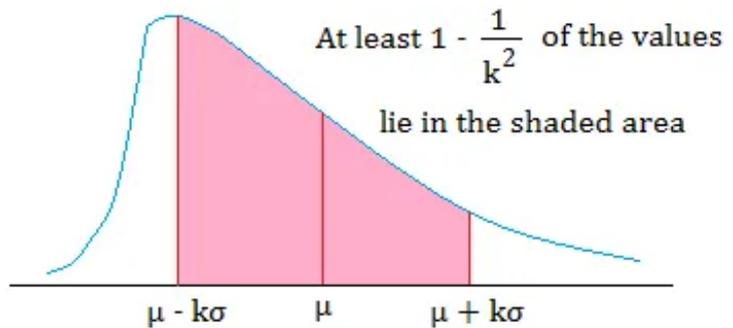


Chebychev 부등식

확률변수  $X$  가 평균  $\mu$ , 분산  $\sigma^2$  을 갖는 경우 분포의 형태와 상관 없이 양의 상수  $k$  에 대하여 다음이 성립한다.

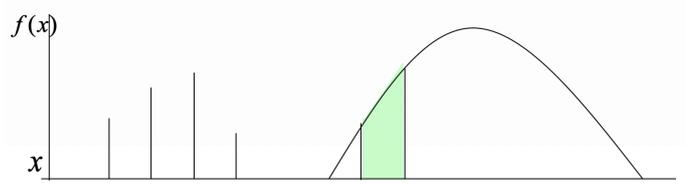
$$P(|X - \mu| \leq k\sigma) \geq 1 - \frac{1}{k^2}$$

- $k = 2$  : 평균을 중심으로  $\pm 1$  표준편차 구간에는 적어도 75% 데이터가 포함되어 있음
- $k = 3$  : 평균을 중심으로  $\pm 1$  표준편차 구간에는 적어도 89% 데이터가 포함되어 있음
- $k = 4$  : 평균을 중심으로  $\pm 1$  표준편차 구간에는 적어도 95% 데이터가 포함되어 있음



## 확률 모형(probability model)이란

확률 모형이란 확률 변수의 확률 분포 함수 (probability density function)를 의미한다. 확률 분포 함수는 확률 변수( $x$ )가 가질 수 있는 각 값을 정의역(domain) 확률( $f(x)$ )을 치역으로(range) 한 함수이다. 아래 그림은 이산형 확률 밀도 함수와 연속형 확률 분포(밀도) 함수의 예이다.



이산형 경우에는 막대의 높이가 (히스토그램에서는 바의 높이) 연속형인 경우에는 면적이 확률이다. 그러므로 연속형 확률 분포 함수에서는  $x$ 의 단일 값에서 확률은 0이다.

### 모집단 분포 가정

다음은 모집단의 분포 형태  $f(x)$ 를 가정하는 예제이다.

- 모집단 전체를 조사한 경우 전체 자료로부터 히스토그램을(이것이 확률 분포 함수이다. 물론 정확한 함수 식은 알 수 없지만) 그리거나 상대 빈도 개념으로 관심 구간의 확률을 구할 수 있다. (예) 한남대학교 학생 중 용돈이 30,000(원)~35,000(원)인 학생의 비율(확률)은? 전체 12,000명 중 용돈이 이 구간에 속하는 학생 수가 확률이 된다.
- 자료를 시뮬레이션(simulation: 모집단 가정) 할 때 사용한다.
- 회귀분석이나 분산 분석에서 오차항에 대한 정규 분포 가정이 있다. 이 가정이 무너지면 회귀 계수(t-검정), 모형의 유의성(F-검정) 검정이 불가능하다.
- 소표본(표본의 크기  $n < 20 \sim 30$ )일 경우 모평균에 대한 가설 검정 시 모집단은 정규 분포임을 가정한다.

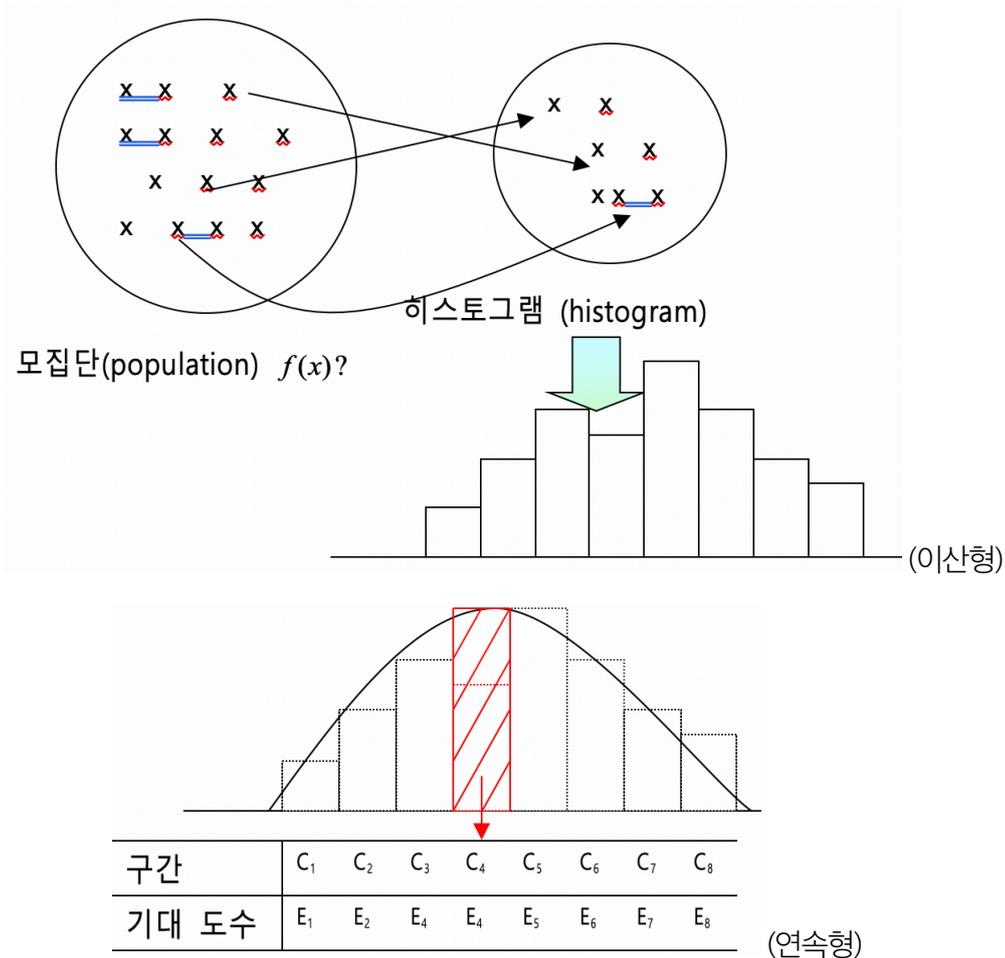
### 모집단 분포 가정이 불가능한 경우

모집단의 분포를 가정하지 않으면 어떻게 확률 분포를 알 수 있나? 표본 자료의 분포(즉 표본 분포)를 이용할 수 밖에 없다.

- (Goodness-of-fits:적합성 검정) : 빈도표 활용 검정통계량 방법  $\chi^2$ -검정
- 그래프 이용 방법: P-P plot 방법, 시각적 방법, rule of thumb

Frequency table (빈도표) 개념 이용하기 ~ χ<sup>2</sup>-분포 적합성 검정

표본 자료로부터 모집단 확률 밀도 함수를 어떻게 구할 수 있는가? 히스토그램으로부터 확률분포함수를 구한다? 불가능하다. 접근 방법은 표본 자료로부터 빈도표를(이를 관측 빈도) 만들고 (histogram과 동일) 모집단이 따를 것 같은 분포로부터(예:정규분포) 빈도표(이를 기대 빈도)를 만들어 비교하면 빈도의 차이가 거의 없으면 모집단은 그 분포를 따른다고 하자 그렇지 않으면 기각한다.



표본 분포가 설정한 모집단 분포와 동일하다면 관측 도수와 (observed frequency) 기대 도수는 (expected frequency) 비슷한 값일 것이다. 즉  $O_1 \approx E_1, O_2 \approx E_2, \dots, O_k \approx E_k$  (위 예에서는  $k = 8$ )

$$TS = \frac{\sum_{i=1}^k (O_i - E_i)^2}{E_i} \sim \chi^2 (df = k - c - 1)$$

검정통계량 (test statistics) ?

- c = 모수 추정 개수

Probability Plot: 시각적 방법

- 두 데이터의 실증적 empirical 분포함수는 동일한가?
- 이론적 분포함수와 데이터의 분포함수는 동일한가? 보여주는 시각적 그래프

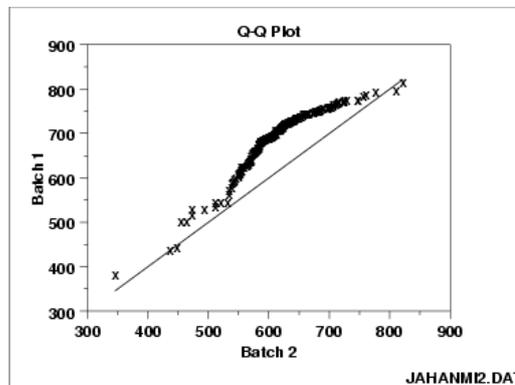
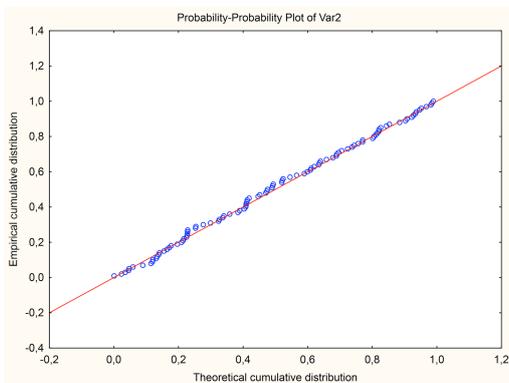
Probability-Probability plot

두 데이터의 누적분포함수를 2차원 그래프에 표현함, X-축에는 정규분포의 누적분포함수  $F(z)$ , Y-축에는 데이터 누적분포함수  $F(x)$

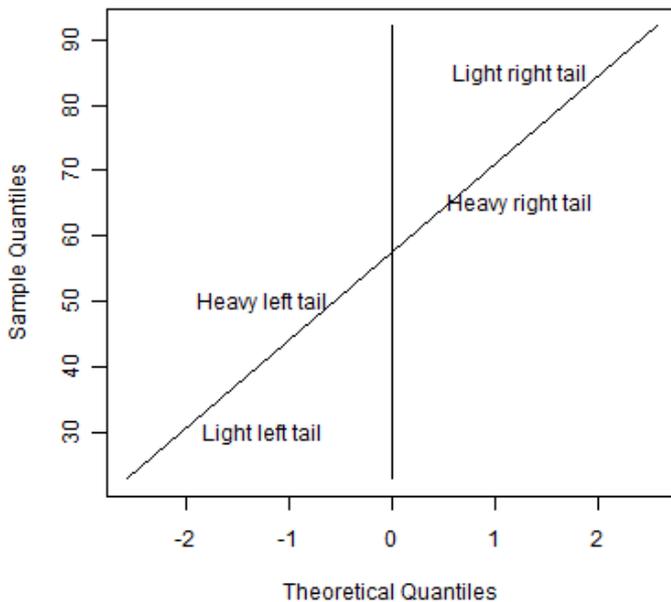
Quantile-Quantile plot

두 데이터의 누적분포함수를 2차원 그래프에 표현함, X-축에는 한 데이터의 p-백분위 값

$F^{-1}(p_i = (i - 0.5) / n)$ , Y-축에는 다른 데이터 p-백분위 값  $F^{-1}(p)$



Interpretation



통계량 활용 - 치우침 판단

평균 왜도 pearson moment skewness

- 모집단 왜도  $\tilde{\mu}_3 = E\left(\frac{X - \mu}{\sigma}\right)^3 = \frac{\mu_3}{\sigma^3}$
- 표본왜도 :  $skew = \frac{\sum (x_i - \bar{x})^3 / n}{(\sum (x_i - \bar{x})^2 / n)^{3/2}}$
- 정규분포의 왜도는 0이고 지수분포는 2이다.

중앙값 활용

pearson first skewness (mode skewness)

$$skew = \frac{mean - mode}{std}$$

Pearson's second skewness coefficient (median skewness)

$$skew = \frac{3(mean - median)}{std}$$

사분위 기반 왜도

$$skew = \frac{(Q_3 + Q_1 - 2Q_2)}{IQR}$$

Groeneveld & Meeden's coefficient

$$skew = \frac{mean - median}{E(|X - median|)}$$

- 정규분포=0, 우로 치우침 +, 좌로 치우침 - : 이는 통계량의 분포를 모르므로 정규분포 가설을 검정할 수 없어 시각적 판단 수준임



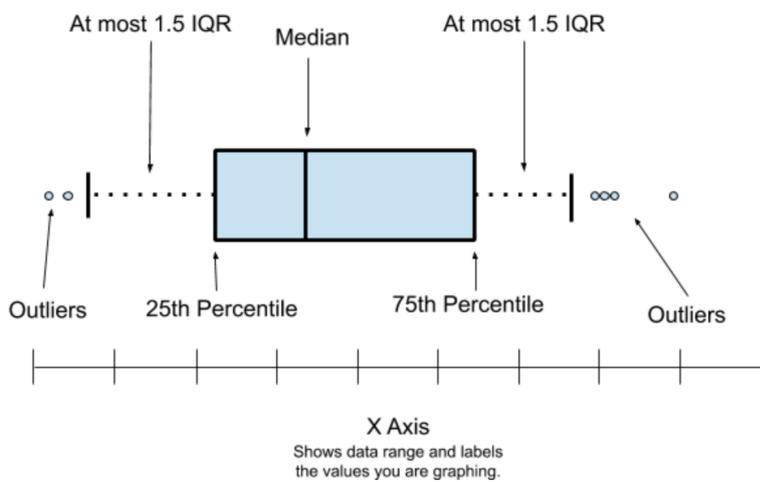
이상치 진단 anomaly detection

벨모양 좌우대칭 분포 z-score

실증적 법칙 empirical rule 에 의하면  $z = \frac{(x - m(x))}{s(x)}$  값은  $\pm 2$  범위 내에 95%가 속하므로 z-점수가 2를 초과하면 이상치로 판단한다.  $m = mean, s = standard deviation$

모든 분포 형태 적용

상자 그림 box plot



Robust z-점수

$$robust - z = \frac{|x - med(x)|}{mad(x)}, MAD = 1.4826 \times median(|x_i - med(x)|)$$

$med = median, mad = median absolute deviation$

[참고 시험 숙련도 Proficiency test]

$rz = \frac{x_i - MD}{0.7413 * IQR}$	▷ $ rz  \cong 0$ : 매우 일치
	▷ $ rz  < 2$ : 양호
	▷ $2 \leq  rz  < 3$ : 주의
	▷ $3 \leq  rz $ : 미흡

이산형 확률모형

공정 주사위 판단

보유한 주사위가 공정한지 fair 알아보기 위하여 1,000번을 던져 나온 결과를 정리한 것이다. 주사위가 공정한지 유의수준 5%에서 검정하시오.

눈금	1	2	3	4	5	6
빈도	150	160	165	155	170	200

통계적 가설

귀무가설 : 주사위는 공정하다. 각 눈금이 나올 확률은  $\frac{1}{6}$ 이다.

대립가설 : 주사위는 공정하지 않다.

기대빈도 계산

귀무가설이 옳다는 가정 하에 계산되는 빈도이다.

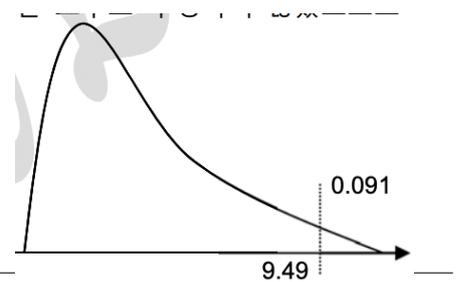
눈금	1	2	3	4	5	6
빈도 $O_i$	150	160	165	155	170	200
기대빈도 $E_i$	1000/6	1000/6	1000/6	1000/6	1000/6	1000/6

검정통계량 및 샘플링 분포

$$ts = \sum_i \frac{(O_i - E_i)^2}{E_i} \sim \chi^2(df = k - c - 1), k = \text{셀의크}$$

기,  $c =$  추정된 모수의 개수

본 예제의 경우  $k = 6, c = 0$ 이다.



유의확률 p-value 계산

$$p - value = P(\chi^2(df, \alpha) \geq ts)$$

```
import numpy as np
x=[1,2,3,4,5,6]
f=[150,160,165,155,170,200]
e=np.repeat(1000/6,6)
E
array([166.66666667, 166.66666667, 166.66666667, 166.66666667,
       166.66666667, 166.66666667])
```

```
import scipy.stats as st
ts=sum((f-e)**2/e)
print('Test statistic=%.2f | p-value=%.3f'%(ts,1-st.chi2.cdf(ts,5)))
```

↳ Test statistic=9.50 | p-value=0.091

유의확률이 유의수준 5%보다 크므로 귀무가설을 기각할 수 없어 주사위는 공정하다.

### 성비는 공평한가?

우리나라 출생 아이의 성비가 동일한지 알아보기 위하여 자녀가 3인인 1,000 가구의 남아 수를 조사한 자료이다. 이를 이용하여 성비가 동일한지 검정하시오.

남자 아이 수	0	1	2	3
빈도	100	350	400	150

### 통계적 가설

귀무가설 : 남아, 여아 비율은 동일하다.

대립가설 : 동일하지 않다.

### 기대빈도 계산

귀무가설이 옳다는 자녀가 3인인 경우 남자의 수  $X$ 는 이항분포  $B(n = 3, p = 0.5)$ 을 따른다.

그러므로 남자아이 수가  $i$ 명 일 빈도= $P(X = i | X \sim B(3,0.5)) * 1000, i = 0,1,2,3$

### 검정통계량 및 샘플링 분포

$$ts = \sum_i \frac{(O_i - E_i)^2}{E_i} \sim \chi^2(df = k - c - 1), k = \text{셀의 크기}, c = \text{추정된 모수의 개수}$$

본 예제의 경우  $k = 4, c = 0$ 이다.

### 유의확률 p-value 계산

$$p - value = P(\chi^2(df, \alpha) \geq ts)$$

```
import numpy as np
import scipy.stats as st
x=[0,1,2,3]
f=[100,350,400,150]
e=st.binom.pmf(x,3,0.5)*1000; e
```

```
↳ array([125., 375., 375., 125.]
```

```
import scipy.stats as st
ts=sum((f-e)**2/e)
print('Test statistic=%.2f | p-value=%.3f'%(ts,1-st.chi2.cdf(ts,3)))
```

```
↳ Test statistic=13.33 | p-value=0.004
```

유의확률이 0.004로 유의수준 5%보다 작으므로 기각되고 2명, 3명 남자 빈도가 이론빈도보다 높으므로 우리나라 남아비율이 높다고 할 수 있다.

### 연습문제

다음은 한남대학교 정문을 통과하는 차량의 수가 Poisson 분포를 따르는지 알아보기 위하여 1 분마다 차량 통과 회수를 300 회 조사하였다. 아래 자료를 이용하여 Poisson 분포를 따르는지 검정하시오. (유의수준=0.05)

통과 차량	0	1	2	3	4	5	6	7
관측 빈도	20	54	74	67	45	25	11	4

### 연속형 확률모형

연속형 확률변수에 대한 확률모형 적합성은 정규분포를 따르는지 보는 것이 가장 중요하다. 왜냐하면 모든 통계적 방법론이 정규분포(적어도 벨모양의 좌우 대칭에 근사)를 가정하거나 치우침이 없다는 가정을 근거로 개발되었다.

#### 통계적 가설

데이터의 분포가 이론적 정규분포를 따르는지 검정하는 적합성 검정임

- 귀무가설 : 데이터 모집단 분포는 정규분포이다
- 대립가설 : 정규분포를 따르지는 않는다 <=> 그러나 어떤 분포인지는 모른다.

```
import numpy as np
data=np.random.exponential(0.5,100)
```

평균이 0.5인 지수분포를 따르는 난수 데이터 100개를 표본추출하였다.

#### Shapiro Wilk W-통계량

$$W = \frac{\left(\sum_{i=1}^n a_i x_{(i)}\right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}, \text{ 상수 } a_i \text{ 는 분산행렬을 이용하여 구함}$$

$$Z_n = \begin{cases} (-\log(\gamma - \log(1 - W_n)) - \mu) / \sigma & \text{if } 4 \leq n \leq 11 \\ (\log(1 - W_n) - \mu) / \sigma & \text{if } 12 \leq n \leq 2000 \end{cases}$$

유의확률이 0.05보다 작으므로 귀무가설이 기각되어 데이터는 정규분포를 따르지 않는다.

```
import scipy.stats as stats
stats.shapiro(data)
```

```
↳ (0.7728214859962463, 3.929337064056959e-11)
```

#### Kolmogorov D-통계량

$$D = \max_x \left| F_n(x) - \Phi(x) \right|, \Phi(x) \text{ 누적정규분포, } F_n(x) \text{ 데이터누적분포함수}$$

유의확률이 매우 작아 귀무가설이 기각되어 정규분포를 따르지 않는다. 모수 추정 결과를 매개변수로 넣을 수 있다.



```
import scipy.stats as stats
stats.kstest(data, 'norm', args=(data.mean(), data.std()))
```

```
KstestResult(statistic=0.1846542541771728, pvalue=0.001858923062673114)
```

적합성 검정 가능한 분포

dist{'norm', 'expon', 'logistic', 'gumbel', 'gumbel\_l', 'gumbel\_r', 'extreme1'} 가능한 함수

귀무가설 : 데이터는 지수분포를 따른다.

대립가설 : 데이터는 지수분포를 따르지 않는다.

유의확률이 0.629로 귀무가설을 기각하지 못하므로 지수분포를 따른다.

```
import scipy.stats as stats
stats.kstest(data, 'expon', args=(0, data.mean()))
```

```
KstestResult(statistic=0.0744020062140947, pvalue=0.6297010879529599)
```

Anderson-Darling AD 통계량

$$A^2 = n \int (Fn(x) - \Phi(x))^2 \left| \Phi(x)\Phi(1-x) \right|^{-1} d\Phi(x)$$

통계량 값이 6.69로 가장 큰 기각역 값 1.053 (여기에 해당하는 유의수준은 0.01)보다 크므로 귀무가설이 기각되어 정규분포를 따르지 않는다.

```
import scipy.stats as stats
stats.anderson(data, dist='norm')
```

```
AndersonResult(statistic=6.699223575977072, critical_values=array([0.555, 0.632, 0.759, 0.885, 1.053]),
significance_level=array([15. , 10. , 5. , 2.5, 1. ]))
```

대부분의 분포에 대한 적합성 검정은 가능하다. scipy.stats 분포

귀무가설 : 데이터는 지수분포를 따른다.

대립가설 : 데이터는 지수분포를 따르지 않는다.

유의수준 15% 기각값보다 작으므로 귀무가설을 기각하지 못하므로 지수분포를 따른다.

```
import scipy.stats as stats
stats.anderson(data, dist='expon')
```

```
AndersonResult(statistic=0.5542469038363862, critical_values=array([0.917, 1.072, 1.333, 1.596, 1.945]))
```



해결방안 : 정규변환 Normal Transformation

간단한 정규변환 normal transformation 방식

우로 치우침 :  $\sqrt{X} \rightarrow \ln(X) \rightarrow \frac{1}{X}$  -> 치우침의 정도가 극심

좌로 치우침 :  $\sqrt{\max(X + 1) - X} \rightarrow \ln(\max(X + 1) - X) \rightarrow \frac{1}{\max(X + 1) - X}$

Modified Tukey Ladder of Power

$$Y = \begin{pmatrix} X^\lambda \text{ if } \lambda > 0 \\ \ln(X) \text{ if } \lambda = 0 \\ -X^\lambda \text{ if } \lambda < 0 \end{pmatrix}$$

Box-Cox transformation : George Box and David Cox

$$Y = \frac{X^\lambda - 1}{\lambda}, \text{ 단 } \lambda = 0 \text{ 이면 } Y = \ln(X)$$

Tukey 변환가 동일하지만 최적의  $\lambda$  값은 MLE 방법에 의해 찾음

Box-Cox 함수를 사용하면 최적  $\lambda(0.22)$  값과 정규변환된(xt) 값이 출력된다. 정규변환된 값에 대한 S-W 정규성 검정을 하면 정규분포를 따른다. 당연한 결과이다.

<pre>import scipy.stats as stats xt,alpha = stats.boxcox(data)</pre>	<pre>1 alpha 0.22562423703607506</pre>
<pre>import scipy.stats as stats stats.shapiro(xt)</pre>	<pre>↳ (0.9932992458343506, 0.9054390788078308)</pre>



함수 적합

선형함수 linear function

모형 & 데이터

$$Y_i = \alpha + \beta X_i + e_i \quad i = 1$$

<pre>def func(x, a, b):     return a*x + b</pre>	함수 설정
<pre>import numpy as np x = np.linspace(0, 10, 100)</pre>	설명변수 X [0~10] 정수를 100개 동일 구간으로 나누어 저장

```
Out[26]: array([ 0.          ,  0.1010101 ,  0.2020202 ,  0.3030303 ,  0.4040404 ,
                0.50505051,  0.60606061,  0.70707071,  0.80808081,  0.90909091,
                1.01010101,  1.11111111,  1.21212121,  1.31313131,  1.41414141,
                1.51515152,  1.61616162,  1.71717172,  1.81818182,  1.91919192.]
```

```
y=func(x, 1, 2)+0.9*np.random.normal(size=len(x))
```

$y = 1 + 2 * x$  함수값에  $0.9 * N(0,1)$  난수 생성( $e_i$ ) 값을 더한다.

가장 적합한 함수 구하는 규칙 Least Square Methods

관측치  $y_i$ 와 적합치  $\hat{Y}_i = \hat{\alpha} + \hat{\beta}x_i$ 의 차이의 제곱합이 최소가 되는 모수  $\alpha, \beta$  구하는 방법

$$\min_{\alpha, \beta} \sum_i^n (y_i - \alpha - \beta x_i)^2$$

```
from scipy.optimize import curve_fit
beta, est_cov = curve_fit(func,x,y)
```

beta에는 OLS 추정값  $\hat{\alpha}, \hat{\beta}$ 가 저장되고 est\_cov에는 추정분산이 출력된다. 대각행렬이 각 모수의 추정분산이 된다.

beta	est_cov
array([1.06267426, 1.55151878])	array([[ 0.00096514, -0.00482569],         [-0.00482569,  0.03233374]])

회귀분석과 결과 비교

```
from scipy import stats
import numpy as np
slope, intercept, r_value, p_value, std_err=stats.linregress(x,y)
slope, intercept, r_value, p_value, std_err
```

Out[33]: (1.0626742610849165,  
1.5515187834324884,  
0.9605816298688206,  
2.7442134254151623e-56,  
0.031066665621587178)

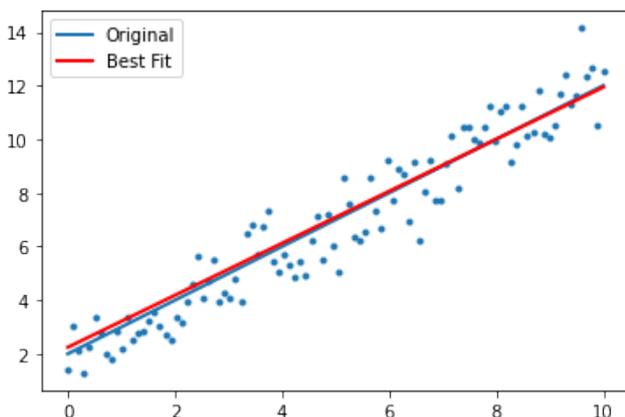
```
import statsmodels.api as sm
model=sm.OLS(y,sm.add_constant(x))
fit=model.fit()
fit.summary()
```

<b>Dep. Variable:</b>	y	<b>R-squared:</b>	0.923
<b>Model:</b>	OLS	<b>Adj. R-squared:</b>	0.922
<b>Method:</b>	Least Squares	<b>F-statistic:</b>	1170.

	coef	std err	t	P> t	[0.025	0.975]
<b>const</b>	1.5515	0.180	8.628	0.000	1.195	1.908
<b>x1</b>	1.0627	0.031	34.206	0.000	1.001	1.124

```
import matplotlib.pyplot as plt
plt.scatter(x, y, marker='.')
plt.plot(x, 2+1*x, linewidth=2)
plt.plot(x, func(x,*popt), color='red', linewidth=2)
plt.legend(['Original', 'Best Fit'], loc=2)
plt.show()
```



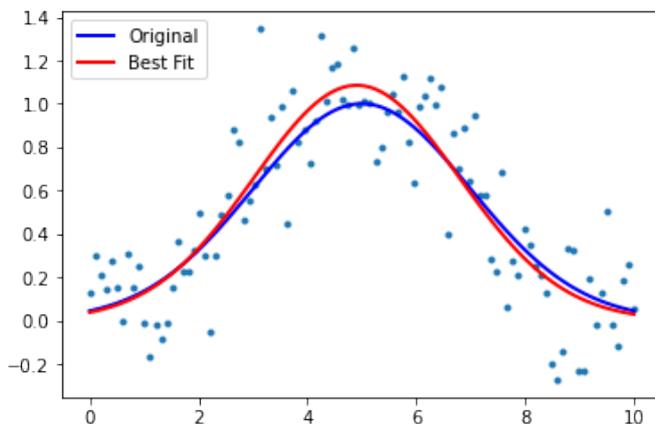
비선형함수

$$y_i = a \exp\left(\frac{-(x-b)^2}{2c^2}\right)$$

```
def func(x, a, b, c):
    return a*np.exp(-(x-b)**2/(2*c**2))
x = np.linspace(0, 10, 100)
y = func(x, 1, 5, 2) # 답인 y들과
y_gen = y + 0.2*np.random.normal(size=len(x)) # noise
beta,est_cov=curve_fit(func, x, y_gen)
beta
```

Out[40]: array([1.08475072, 4.90685069, 1.88868034])

```
plt.scatter(x, y_gen, marker='.')
plt.plot(x, y, linewidth=2, color='blue')
plt.plot(x, func(x, *beta), color='red', linewidth=2)
plt.legend(['Original', 'Best Fit'], loc=2)
plt.show()
```



연습문제

$$a_0 \exp\left(\frac{-(x-b_0)^2}{2c_0^2}\right) + a_1 \exp\left(\frac{-(x-b_1)^2}{2c_1^2}\right)$$

```
x = np.linspace(0, 20, 200)
```

