

제 5 장 다중회귀분석 (Multiple Regression Analysis)

1. 다중회귀 모형의 구조

1) 다중회귀분석이란: 설명변수(독립변수)가 2 개 이상인 회귀모형을 분석대상으로 삼고있다

→ 기본가정: 설명변수는 2 개이며, 각설명변수는 종속변수와 선형관계에 있다

- 다중분석의 의의: 분석내용을 향상시킬 수 있다

a) 추가적인 독립변수를 도입함으로써 오차항의 값을 줄일 수 있다

b) 단순회귀분석의 단점을 극복 할 수 있다

→ 종속변수를 설명하는 독립변수가 두개일 때 단순회귀모형을 설정한다면 모형설정(specification)이 부정확할 뿐 아니라 종속변수에 대한 중요한 설명변수(독립변수)를 누락함으로써 계수 추정량에 대해 편의(bias)를 야기 시킬 수 있으므로 단순회귀분석은 그 유용성을 상실하게 된다. 따라서 다중회귀분석을 통해 편의현상(bias)을 제거할 수 있다

2) 다중회귀모형의 일반형

- 종속변수 Y_i 가 상수항과 k 개의 독립변수 $X_{1i}, X_{2i} \dots X_{ki}$ 에 의해 설명되는 모집단

의 다중회귀모형은, 기본모형: $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i$

→ 설명변수 k 개, 모수 $(k+1)$ 개

- Matrix 형태

3) 다중회귀 모형의 기본가정

a) 회귀모형은 모수에 대해 선형인 모형이다: $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \varepsilon_i$

b) 독립변수 X_{1i}, X_{2i} 는 비확률(nonstochastic)이다

c) 오차항의 평균은 0 이다: $E(\varepsilon_i) = 0$

d) 오차항의 분산은 모든 관찰치에 대해 σ^2 의 일정한 분산을 갖는다 (동분산:

homoskedasity): $\text{Var}(\varepsilon_i) = E[\varepsilon_i - E(\varepsilon_i)]^2 = E(\varepsilon_i^2) = \sigma^2$

e) 서로다른 관찰치간의 오차항은 상관이 없다: $\text{Cov}(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) = 0$ ($i \neq j$)

→ 오차항들은 서로 독립적이며 그들의 공분산은 0 이다

f) 오차항은 각독립변수와 독립적이다: $E(X_i, \varepsilon_i) = X_i E(\varepsilon_i) = 0$

g) 오차항이 정규분포를 따르며, $\varepsilon_i \sim N(0, \sigma^2)$

→ 이상의 가정들은 기존의 단순회귀분석의 경우와 기본적인 내용에 있어서 큰 차이가 없으나 다음의 두가지 가정은 다중회귀분석에만 적용이 된다

h) 독립변수간에는 정확한 선형관계가 없다: $\rho(X_{1i}, X_{2i}) \neq \pm 1$

→ 한 독립변수가 다른 독립변수와 1 차함수관계에 있어서는 안된다

→ 만일 $\rho(X_{1i}, X_{2i})$ 의 절대값이 1 에 가까워지면, 최소자승법의 적용이 어렵게 되며, 이러한 현상을 다중공선성(multicollinearity)이라 하고 특히, $\rho(X_{1i}, X_{2i}) = \pm 1$ 인 경우에는 완전공선성(perfect collinearity) 이라 한다.

i) 관측된 값들의 수는 독립변수의 수보다 최소한 2 이상 커야 한다.

→ 독립변수의 수가 k 라면, 미지수인 절편을 포함하여 총(k+1)의 모수를 추정해야하며, 이를 위해 관측치 수(표본수:n)은 (k+1)보다 커야 연립방정식 체계를 이용하여 최소자승법을 사용할 수 있다: $n > k+1$

→ 자유도는 $n-(k+1)$ 이고, 최소한 자유도가 1 이상 되기위해 $n > k+2$ 가 필요하다

4) 다중회귀분석 계수의 해석

- 독립변수가 여러 개인 다중회귀분석에서의 회귀계수의 해석은 다른 독립변수가 불변일 때 (통제된 상태에서), 해당되는 독립변수의 변화에 따른 종속변수의 평균변화량을 나타내는 직접효과(direct effect) 또는 순효과(net effect)를 뜻한다.

→ 이는 독립변수가 여러 개이므로 이들간에 서로 상관관계를 있을 수 있기 때문에 한 독립변수의 값이 다른 독립변수에 영향을 미칠 수 있다

2. 최소자승법에 의한 다중회귀모형의 추정

- 모집단에 대한 기본가정들이 충족된다는 가정하에 최소자승법을 이용하여 표본회귀선을 도출할 수 있다

→ 다중회귀모형의 표본회귀 모형: $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + e_i$

⇒ 모집단의 모수인 α, β_1, β_2 에 대한 최소자승 추정량 ($\alpha^{\wedge}, \beta_1^{\wedge}, \beta_2^{\wedge}$)은 최소자승법을 이용하여 추정치를 구한다 (표본의 크기: n)

⇒ $\min L = \min [\sum_{i=1,n} e_i^2] = \min [\sum_{i=1,n} (Y_i - Y_i^{\wedge})^2] = \min [\sum_{i=1,n} (Y_i - \alpha^{\wedge} - \beta_1^{\wedge} X_{1i} - \beta_2^{\wedge} X_{2i})^2]$,

⇒ $(\partial L / \partial \alpha^{\wedge}) = (\partial L / \partial \beta_1^{\wedge}) = (\partial L / \partial \beta_2^{\wedge}) = 0$

⇒ 일반적으로 추정계산과정이 매우 복잡하고 시간이 많이 소요되는 관계로 컴퓨터 프로그램을 이용하여 계산한다.

⇒ 최소자승 추정량의 특성

a) 불편의 추정량 (unbiased estimator): $E(\hat{\beta}_i) = \beta_i$

b) 일치 추정량 (consistent estimator): $\hat{\beta}_i \rightarrow \beta_i$ as $n \rightarrow \infty$

c) BLUE (Gauss-Markov Theorem)

→ 추정량의 분산

a) $\text{var}(\hat{\beta}_1) = \sigma^2 / [(1 - r_{23}^2)(\sum(X_{2i} - \mathbf{X}_2)^2)]$, b) $\text{var}(\hat{\beta}_2) = \sigma^2 / [(1 - r_{23}^2)(\sum(X_{3i} - \mathbf{X}_3)^2)]$

→ $r_{23} = [\sum(X_{2i} - \mathbf{X}_2)(X_{3i} - \mathbf{X}_3)] / [\sqrt{\sum(X_{2i} - \mathbf{X}_2)^2} \sqrt{\sum(X_{3i} - \mathbf{X}_3)^2}]$

⇒ 추정량의 분산에 영향을 미치는 요인들

a) 오차항의 분산(σ^2)이 작을수록 추정량의 분산이 작아진다

b) 표본의 크기(n)가 클수록 추정량의 분산이 작아진다

c) 설명변수의 편차($X_{ki} - \mathbf{X}_k$)들이 클수록 추정량의 분산이 작아진다

다

d) 설명변수들간의 상관관계(r_{23})가 작을수록 추정량의 분산이 작아

진다

⇒ 설명변수들간의 상관관계(r_{23})가 클수록, 설명변수들간의 공선성

(collinearity)이 강해지므로 추정량의 분산값이 커지게 되어 정

확한 추정량의 값을 구하기가 어렵게 됨.

- 오차항의 분산 추정치: 오차항의 분산(σ^2)이 일반적으로 알려져있지 않으므로

표본의 분산(s^2)을 대신 이용한다 $\rightarrow s^2 = \sum_{i=1,n} e_i^2 / (n - (k+1))$ (k 는 독립변수의

개수)

3. 다중회귀모형에 대한 가설검정

- 다중분석회귀의 기본가정이 성립되면 최소자승 추정량은 BLUE 특성을 가지나 각 독립변수가 종속변수의 변화를 설명하는데 유용한지의 여부를 검정하여야 한다

1) 모수 β 에 대한 가설검정: t-검정

- 개별 회귀계수 β 에 대한 가설검정은 t-분포를 이용하여 이루어진다

$$\rightarrow (\alpha^{\wedge} - \alpha) / s_{\alpha^{\wedge}} \sim t(n-k-1), (\beta_j^{\wedge} - \beta_j) / s_{\beta_j^{\wedge}} \sim t(n-k-1), j = 1, 2.$$

$\Rightarrow \varepsilon_i \sim N(0, \sigma^2)$ 가정하에서 추정량(α^{\wedge} , β_1^{\wedge} , β_2^{\wedge})들이 정규분포를 따르는 오차항 ε_i 와 1 차함수관계를 갖게 되므로 이들 역시 정규분포를 따르게 되고, 모분산값, $\text{var}(\varepsilon_i) = \sigma^2$ 이 알려지지 않았기 때문이다.

\Rightarrow 이 경우 임계치 (critical value)를 구할 때 자유도가 $(n-k-1)$ 임을 유의

- 귀무가설 $H_0: \beta_j^{\wedge} = \beta_j^0$ 의 가설을 검증하는 경우 단순회귀분석의 경우와 같이 양측검정, 단측검정의 방법이 사용되며, 2-t 으뜸법칙과 유의확률에 의한 가설검정을 이용

2) 모형에 대한 검정: F-검정

- χ^2 분포와 F-분포

a) χ^2 분포: 확률변수 X_1, X_2, \dots, X_n 이 정규분포 $N(\mu, \sigma^2)$ 을 따를 때, 표준화변수 $(X_i - \bar{X})$ 의 제곱합의 분포는 자유도(n)을 가진 χ^2 분포를 따른다

$$\rightarrow \sum (X_i - \bar{X})^2 / \sigma^2 \sim \chi^2(n)$$

→ F-분포는 $(0, \infty)$ 의 구간에서 긴오른쪽 꼬리를 가진 형태를 가진다.

b) F-분포: 확률변수 X_1, X_2, \dots, X_{m1} 이 정규분포 $N(\mu_1, \sigma_1^2)$ 을 따르고, Y_1, Y_2, \dots, Y_{m2} 이 정규분포 $N(\mu_2, \sigma_2^2)$ 을 따를 경우, 표준화변수의 제곱합의 비율은 자유도(m_1, m_2)를 가진 F 분포를 따른다.

$$\rightarrow \{[\sum (X_i - \bar{X})^2 / \sigma_1^2] / m_1\} / \{[\sum (Y_i - \bar{Y})^2 / \sigma_2^2] / m_2\} \sim F(m_1, m_2)$$

[m_1 :분자 자유도(numerator degree of freedom: df_n), m_2 : 분모자유도 (denominator degree of freedom: df_d)]

→ F-분포는 $(0, \infty)$ 의 구간에서 긴오른쪽 꼬리를 가진 형태를 가진다.

⇒ 만일 확률변수 $T \sim t(m_2)$ 이면, $T^2 \sim F(1, m_2)$ 의 분포를 갖는다

⇒ F-분포 형태

- 모형의 적합도(유의성)에 대한 가설검정

→ t-분포를 이용한 검정은 단순히 개별 독립변수들이 종속변수의 변화를 설명하는데 유용한지의 여부를 확인할 수 있으나 모든 독립변수집단 전체가 총체적으로 보아 종속변수를 설명할 수 있는지의 여부를 확인 할 수 없다

→ 모형의 적합도에 대한 가설검정은 모든 독립변수가 종속변수에 영향을 미치는가를 검정한 것이다

→ 두개의 독립변수를 가진 모형인 경우: $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + e_i$

⇒ 모형의 유의성 검정

⇒ $H_0: \beta_1 = \beta_2 = 0$ vs. $H_1: \text{적어도 하나의 } \beta \text{ 는 } 0 \text{ 이 아니다}$

a) 평균오차자승 합(MSE: mean square error) = $RSS / (n-k-1)$, $RSS = \sum_{i=1,n} e_i^2$

b) 평균회귀자승 합(MSR: mean square regression) = ESS/k , $ESS = \sum_{i=1,n} (\hat{Y} - Y)^2$,

→ $F_{(k, n-k-1)} = MSR/MSE = [\sum_{i=1,n} (\hat{Y} - Y)^2 / k] / [\sum_{i=1,n} e_i^2 / (n-k-1)] \sim$

$F(k, n-k-1)$: 만일 F-통계치가 유의수준 α 에서 자유도(k-1, n-k)의 임계치(F-분포값) 보다 크면, 귀무가설이 기각되어 독립변수 전체가 종속변수의 설명에 유의적 (statically significant) 따라서 독립변수 전체가 종속변수 설명에 유의

적이지 못하다(statically insignificant) .

- 회귀계수의 일부분에 대한 가설검정: F-검정법

→ 가설들에 대한 F-검정법은 제약없는 원래의 모형(unrestricted model)으로부터 도출된 잔차의 제곱합(RSS_U)과 귀무가설이 참이라는 가정하에서의 모형(restricted model)에서 도출된 잔차의 제곱합(RSS_R)을 비교하는 것에 기반을 둔 검정방법이다

→ 만일 귀무가설에서 가설의 수(제약식의 수)가 J 개일 경우,

$(RSS_R - RSS_U)/\sigma^2 \sim \chi^2(J)$ 그리고 $(RSS_U)/\sigma^2 \sim \chi^2(n-k-1)$ 의 분포특성을 갖는다.

⇒ F-검정통계치 = $[(RSS_R - RSS_U)/J] / [(RSS_U)/(n-k-1)] \sim F(J, n-k-1)$

⇒ 만일 F-검정통계치 값이 주어진 유의수준에 의한 임계치값, 자유도 $(J, n-k-1)$ 의 F-분포값 보다 클 경우 귀무가설을 기각하게 된다

⇒ 만일 F-검정통계치 값이 주어진 유의수준에 의한 임계치값(F_c), 자유도 $(J, n-k-1)$ 의 F-분포값 보다 작을 경우 귀무가설을 채택하게 된다

다

→ 독립변수가 k 개인 다중회귀모형 $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + e_i$

에서 회귀계수 β 의 일부분에 대한 가설검정을 한다

→ 제약된 최소자승 추정치(restricted least squares estimate)와 제약되지 않은 최소자승 추정치(unrestricted least squares estimate) 사용 한다

→ 예) $H_0: \beta_{k-1} = \beta_k = 0$ (X_{k-1} 와 X_k 의 두변수만 종속변수에 영향이 없다)

a) 제약된 최소자승 추정치(restricted least squares estimate): 제약조건을 고려한 최소자승 추정치를 구하는 방법

⇒ 귀무가설의 조건을 고려한 회귀분석모형은 $Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_{k-2} X_{k-2i} + e_i$

⇒ 이 제약된 모형을 이용하여 Y 와 $X_1 \dots X_{k-2}$ 에 대하여 회귀분석하여 잔차항의 지급합(restricted RSS: $RSS_R = \sum_{i=1,n} e_i^2$)를 구한다

⇒ 귀무가설의 제약조건을 감안하지 않은 일반적인 회귀모형, $Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + e_i$ 을 이용하여 Y 와 $X_1 \dots X_k$ 에 대하여 회귀분석하여 잔차항의 지급합(unrestricted RSS: $RSS_u = \sum_{i=1,n} e_i^2$)를 구한다

⇒ 만일 귀무가설이 맞다면, $RSS_R \approx RSS_u$ 의 관계가 성립하고, 귀무가설이 성립하지 않으면 $RSS_R > RSS_u$ 이 관계가 되어 두 값간에 차이가 생겨난다.

⇒ 이 경우 가설검정 역시 F-분포를 이용하여 실행한다:

$$F = [(RSS_R - RSS_u)/J] / [RSS_u / (n-k)] \sim F(J, n-k-1), J \text{ 는 제약조건의 계수}$$

- 회귀계수의 선형결합에 대한 검정

- 독립변수가 k 개인 다중회귀모형 $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + e_i$ 에서

회귀계수 β 의 선형결합에 대한 귀무가설을 검정한다

- 예) $H_0: \beta_1 + \beta_2 = 1$

→ 귀무가설하에서 $\beta_1 = 1 - \beta_2$ 이 되며, 이 조건하에서 제약된 회귀모형은

$$Y_i = \alpha + (1-\beta_2)X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + e_i \text{ 이 되며, 이는 다시}$$

$$Y_i - X_{1i} = \alpha + \beta_2(X_{2i} - X_{1i}) + \dots + \beta_k X_{ki} + e_i \text{ 로 바꿀 수 있다}$$

⇒ 이 조건하에서 종속변수($Y - X_1$)를 독립변수($X_2 - X_1$), ... X_k 에 대해 회귀분

석하여 제약된 모형에서의 잔차항의 제곱합 ($RSS_R = \sum_{i=1, n} e_i^{*2}$)을 구한다:

이때, β_1 의 추정치는 $1 - \hat{\beta}_2$

⇒ 제약조건을 감안하지 않은 일반적인 모형으로부터 잔차항의 제곱합 (RSS_u

$$= \sum_{i=1, n} e_i^2$$
)을 구한다

⇒ 검정통계량, $F = [(RSS_R - RSS_u)/J] / [RSS_u / (n-k)] \sim F(J, n-k-1)$, J는 제약식 수

4. 결정계수(R²)와 조정된 결정계수(Adjusted R²: R²): 적합도 검정

- 단순회귀분석의 경우와 같이 결정계수 도출에 필요한 관계식을 정리해보면,

$$\rightarrow \sum_{i=1,n} (Y_i - Y)^2 = \sum_{i=1,n} (Y^{\wedge}i - Y)^2 + \sum_{i=1,n} (Y_i - Y^{\wedge}i)^2: TSS = ESS + RSS$$

$$\rightarrow \text{결정계수, } R^2 = ESS/TSS = 1 - (RSS/TSS)$$

- 다중회귀분석의 경우 독립변수가 여럿 개이기 때문에, R²의 값이 독립변수의 수가 많아짐에 따라 증가한다.

→ 독립변수의 수가 증가함에 따라 잔차항의 제곱 합($\sum_{i=1,n} e_i^2$)이 감소하게 되고 결과적으로 R²의 값이 증가하게 된다.

→ 이는 R²의 값을 정의함에 있어 단순히 전체 변동량과 회귀선에 의해 설명되는 변동량을 비교함으로써 각 변동량이 가지는 자유도를 고려하지 않았기 때문이다.

→ 단순히 R²의 값을 증가시키기 위해 종속변수의 설명에 중요하지 않은 독립변수를 추가 시키는 경우가 발생할 수 있다

- 이러한 문제점을 방지하고 보다 적합한 평가기준을 위해 자유도를 동시에 고려하는 조정된 결정계수(Adjusted R²)를 사용한다

→ 조정된 결정계수(Adjusted R²)를 도출할 경우, 단순한 변동량 대신 자유

도 개념을 구체적으로 고려대상에 포함 시킬 수 있는 분산개념을 사용한다

$$\text{Adjusted } R^2 = 1 - \frac{[\sum_{i=1,n} e_i^2 / (n-k-1)]}{[\sum_{i=1,n} (Y_i - \bar{Y})^2 / (n-1)]} = 1 - (1 - R^2) \frac{(n-1)}{(n-k-1)}$$

⇒ $k > 1$ 이면, $R^2 > R^2$

⇒ 다른 조건이 일정할 때 독립변수 k 가 증가함에 따라 R^2 값은 감소한다: 종속변수의 설명에 유의적(significant)이지 않거나 중요하지 않은 독립변수를 포함시켜 결정계수를 증가 시키는 것을 방지 할 수 있게 한다

⇒ $R^2 > 0$ 이나 $R^2 < 0$ 이 가능하다: 이는 R^2 값이 아주 작은 경우로 고려하고 있는 모형이 자료에 적합하지 않음을 의미한다

⇒ 종속변수가 서로다른 두 모형을 비교할 때, 결정계수값을 비교하는 것은 의미가 없다: 이는 종속변수의 전체변동값이 다르기 때문에 결정계수값을 정확히 비교할 수가 없다

5. 예측

- 기본가정이 충족된다고 볼 수 있는 상황에서 최소자승법에 의해 도출된 표본 회귀선이 적합도나 통계적 유의성 검정에 의한 평가 결과 합당한 추정식으로

판정이 되면, 이 추정식을 이용하여 신뢰할 수 있는 예측을 시행할 수 있다.

- 예측방법은 단순회귀분석과 동일하다:

→ 점예측: 도출된 다중표본회귀식에 임의로 내정된 각독립변수의 값을 대입함으

로써 성립된다: $\hat{Y}_f = \alpha^{\wedge} + \beta^{\wedge}_1 X_{1f} + \beta^{\wedge}_2 X_{2f}$

a) X_{1f} 와 X_{2f} 는 회귀선의 추정과정에서 사용되지 않은 추가적인 값들이며

분석자의 판단에 의거 적절히 책정되는 것이 일반적이다

b) 표본회귀선에 의해 표출된 \hat{Y}_f 란 독립변수의 값(X_{1f}, X_{2f})이 주어졌을 때

평균적으로 기대할 수 있는 종속변수값으로 예측대상이 긴 미래에 예측하

거나 예측에 사용된 독립변수의 값들이 표본회귀선 도출에 사용되었던 독

립변수값들의 평균값과 많은 차이가 있을 때, 점예측치의 실현가능성은

희박해진다.

c) 점예측은 가능한 가까운 미래예측에 한정하여 사용하는 것이 타당하다