

제 8 장 다중공선성(Multicollinearity)

1. 다중공선성 (Multicollinearity)의 성격과 문제점

1) 완전공선성(perfect multicollinearity)

- 회귀모형, $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \varepsilon_i$ 에서 두설명변수가 완전한 선형관계($X_{1i} = \lambda X_{2i}$, $\lambda \neq 0$)인 경우 각 회귀계수에 대해 최소자승추정치를 구할 수 없게 되며, 이러한 경우를 완전 공선성(perfect multicollinearity)이라 한다.

- 일반적으로 k 개의 설명변수를 포함한 회귀모형에서 설명변수간의 관계가

$$\lambda_1 X_1 + \lambda_2 X_2 + \dots + \lambda_k X_k = 0, (\lambda_1 \neq 0 \quad \lambda_2 \neq 0 \quad \dots \lambda_k \neq 0) \text{의 경우 설명변수사이}$$

에 완전공선성이 나타난다고 한다.

2) 다중공선성(multicollinearity)

- 일반적으로 회귀모형에서 설명변수간에 정확한 선형관계(완전 공선성)는 나타나지 않으며, 단지 그 상관관계가 높게 나타나는 문제가 발생하는데, 이경우를 다중공선성(multicollinearity)라 한다: $\rho(X_i X_j) \approx \pm 1$

3) 다중공선성이 추정에 미치는 효과: $Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i$

a) 추정량, $\hat{\beta}_j (j=1..k)$ 이 매우 불안정하게 되어 최소자승추정량 얻을 수 없게 된다

b) $\hat{\beta}_j$ 의 분산값이 매우 커지게 된다

→ $\hat{\beta}_j$ 의 표준오차($s_{\hat{\beta}}$)값이 커짐에 따라 t-검정 통계량이 매우 적게되어 귀무가설

($H_0: \beta_j = 0$)을 기각할 가능성이 부당하게 희박해진다

→ 비록 결정계수 R^2 값이 높고 모형의 적합성(유의성)에 대한 F 값이 높음에도 불

구하고 개별 추정량의 통계적 유의성이 없게 나타난다

c) 회귀계수의 추정치와 통계치가 자료의 크기 변화나 설명변수의 누락이나 부적

절한 변수의 포함등에 의해 민감하게 변하게 된다

2. 다중공선성의 점검

1) 높은 R^2 값과 낮은 t-검정치

- R^2 값은 크고 개별 회귀계수에 대한 t-검정치가 낮은 경우, 각 설명변수들의 종속변수에 대한 설명력은 높으나 각계수의 추정치의 표준오차가 매우 크다는 것을 의미한다. 이는 설명변수간에 다중공선성이 높을 때 나타나는 현상이다

2) 설명변수들간의 높은 상관계수 값(0.9 이상)

- 3) 설명변수를 하나 추가하거나 또는 제거함에 따라 추정치값들이 크게변할 때,
- 4) 관측치(n)의 수를 추가하거나 제거함에 따라 추정치값들이 크게변할 때,
- 5) 중요한 설명변수의 표준오차가 매우 커거나 추정치의 부호가 예상과 다를 때
- 6) 각 추정치에 대한 유의성 검정통계량인 t-통계치가 아주 작음에도 불구하고 귀무가설, $H_0: \beta_1 = \beta_2 = \dots = \beta_j = 0$ 에 대한 검정통계량 F-통계치가 매우 클 때
(종합적 영향력에 비해 개별 설명변수의 영향력이 미미하여 독립적으로 개별 설명변수의 영향력을 분리 추정하기 힘든 경우)

3. 다중공선성에 대한 대책

- 다중공선성을 내포하고 있는 회귀모형의 경우 회귀분석의 목적이 개별개수에 대한 추정이 아니라 종속변수 전체에 대한 예측에 있다면 다중공선성은 문제가 되지 않는다
- 만일 회귀분석 목적이 사용되는 자료의 특성상 개별 설명변수의 종속변수에 대한 효과나 영향을 분리 추정일 경우 이러한 개별변수에 대한 분리 추정을 할 수 없게 되는 문제점이 있으므로 이를 완화 시키거나 해결할 필요가 있다

1) 다중공선성 유발변수의 탐색 및 제거

→ 심각한 다중공선성을 유발시키는 설명변수를 확인한 다음 이들 변수중 추정에 해로운 변수를 제거하는 방법이다

a) 다중공선성 유발변수의 탐색

i) 각 설명변수를 다른 모든 설명변수 들에 대하여 회귀분석 한 다음 R^2

값을 서로 비교하여 가장 큰 R^2 값을 갖는 회귀방정식상의 선형함수관

계가 높은 변수가 다중공선성 문제를 유발시키는 것으로 판정 할 수 있

다

ii) 설명변수 간의 상관계수를 산출한 다음 $H_0: \rho_{ij} = 0$ 에 대한 t-검정통계량,

$t = (\rho_{ij} \sqrt{n-k}) / (\sqrt{1-\rho_{ij}^2})$ 값을 이용하여 귀무가설을 검정한다. 만일 귀무

가설이 기각되면, 두변수는 다중공선성을 유발시키는 것으로 볼 수 있

다.

iii) 특정 설명변수를 제외시켰을때의 R^2 값이 제외시키기 이전의 R^2 값에 비

해 감소하지 않을 경우 이 설명변수에 의해 다중공선성이 높아진 것으

로 볼 수 있다.

b) 다중공선성 유발변수의 제거

i) 선형상관관계가 높거나 높은 다중공선성을 유발시키는 것으로 확인된

두 설명변수와 종속변수의 상관계수를 산출, 비교하여 상관계수값이 작

은 설명변수를 제거한다. 이는 종속변수에 대한 추가적인 설명능력이

상대적으로 작다는 것을 의미하기 때문이다.

ii) β 계수(β coefficient)나 탄력성(elasticity)를 이용한다

→ β 계수(β coefficient) = $\hat{\beta}_i (s_{xi} / s_y)$, $\hat{\beta}_i$ 는 최소자승 추정치

→ 탄력성(elasticity) = $\hat{\beta}_i (X_i / Y)$,

→ β 계수나 탄력성 값을 비교하여 절대치가 작은 변수를 제외 시킨다

- 일단 회귀모형내에 도입된 변수는 합당한 이론이나 가설에 입각하여 채택된 것이므로 무작정 변수를 제거하면 다중공선성 문제는 완화될 수 있으나 때로는 더 심각한 "설정모형 오류"를 유발할 수 있기 때문에 주의해야 한다.

2) 자료와 모형의 보완 및 변형

- 다중공선성문제를 해소하는 궁극적이고 최선이 되는 방법은 표본관측치를 추가적으로 확보하거나 모형을 변형시켜 기존의 표본관측치값에 의해 야기된 다중공선성을 완화시키는 것이다

a) 일차분차(first difference) 또는 비율(ratio)을 사용하는 방법

→ 기본회귀모형, $Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \varepsilon_i$ 대신에, 일차분차식, $\Delta Y_i = \alpha +$

$\beta_1 \Delta X_{1i} + \beta_2 \Delta X_{2i} + \varepsilon_i$ 또는 비율식 $(Y_i / X_{1i}) = \beta_1 + \beta_2 (X_{2i} / X_{1i}) + (\alpha / X_{1i}) + \varepsilon'_i$

을 이용하여 추정함으로써 다중공선성을 완화시킬 수 있다

b) 추가적인 표본관측치를 확보하여 활용하는 방법

→ 추가로 확보하는 자료들은 가능한 기존의 설명변수의 평균값과 상이한

값을 많이 포함시켜야한다