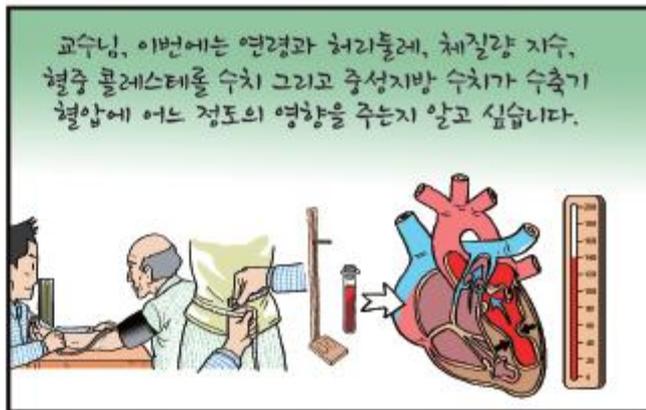


CHAPTER 알기 쉬운 연구방법론

14

회귀분석





- $Y = f(x)$ 의 함수관계에서 x 는 독립변수이고 y 는 종속변수라 할 때 x 에 의해 y 는 영향을 받는다.
- 회귀분석은 x 와 y 의 관계를 찾아내는 분석방법으로 독립변인이 종속변인에 영향을 미치는지 알아보하고자하는 방법
- 연속형 자료에 따른 연속형 자료의 영향력을 검증하고자 할 때

영향을 주는 변수	영향을 받는 변수	통계분석방법
범주형 자료	범주형 자료	카이제곱 검정
	연속형 자료	T검정 분산분석
연속형 자료	연속형 자료	회귀분석 구조방정식
	범주형 자료	로지스틱 회귀분석

- $Y = f(x)$ 에서 x 는 y 에 영향을 미치고 이러한 관계 내에서 회귀분석은 이런 종속 변수와 독립변수의 관계를 찾아내는 분석방법.
- X 를 독립변수 = 설명변수
- Y 는 종속변수 = 반응변수
- 예로 물품의 만족도는 가격, 포장, 맛 등이 영향을 준다. 이때 가격, 포장, 맛이 물품만족도에 어느 정도 영향을 주는가를 분석할 때 사용하고 이것을 식으로 나타낸 것을 단순회귀모형이라 한다.

$$\text{만족도} = \text{회귀계수} + (\text{회귀계수 가격}) + \text{회귀계수 포장} + \text{회귀계수 맛} + \text{오차}$$

이때 회귀계수는 독립변수 요소들이 종속변수인 만족도 어느 정도 영향을 주는가를 수치로 나타내는 것이라 할 수 있다.

회귀분석은 종속변수와 독립변수 둘 다 양적 변수가 되어 하고 만약 종속변수가 질적이고 독립변수가 양적 이면 **로지스트 회귀분석**을 사용해야 한다.

회귀분석은 어떤 연구문제에 적용할 수 있을까?

- 연구문제 예시

1. 부모의 수입이 성적에 미치는 영향

2. 키가 몸무게에 미치는 영향

3. 나이가 스마트폰 사용시간에 미치는 영향

01 회귀 분석

- ① 회귀분석은 변수 간에 서로 종속적인 관계에 있을 때 독립변수의 변화량에 따라 종속변수의 변화량이 어느 정도인지를 일차방정식의 함수관계로 파악할 수 있는 분석방법(선형 회귀식)
- ② 측정된 값들의 분포와 가장 근사한 직선방정식을 찾아낼 수 있는데 이를 직선회귀방정식이라 하며 이는 측정된 값들 사이로 임의로 선을 긋고 측정값들로 부터 임의로 그은 선까지 수직으로 내려 그은 거리의 제곱 R^2 의 총 합이 최소가 되는 방정식을 의미하며 식으로 표현하면
- $$y = \alpha + \beta x + \varepsilon \text{ (종속변수에 영향을 주는 독립변수가 하나)}$$
- $$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \varepsilon \text{ (종속변수에 영향을 주는 독립변수가 둘 이상)}$$

α 는 상수, β 는 회귀계수(기울기), ε 는 오차

참고)) 회귀분석과 상관관계

- 상관관계와 회귀분석의 차이점

두 변수 X, Y에 대하여 X가 독립변수, Y가 종속변수라고 하면

상관관계 : $X \leftrightarrow Y$ 회귀분석 : $X \rightarrow Y$

상관관계는 관련성(한 변수가 커질 때 다른 변수 값이 높거나 낮아지는 경향)에 목적을 둔 것이라면

회귀분석은 예측을 목적(두 변수간의 관계식, 혹은 여러 변수와의 관계식(**회귀모형**)을 구해야함)으로 한다.

예측 : 어떤 알고 있는 변수로부터 그에 대응하는 다른 변수의 값을 알아보는 것

③ 종속변수에 영향을 주는 독립변수가 하나- 단순회귀분석.

종속변수에 영향을 주는 독립변수가 둘 이상이면 다중회귀분석.

④ 독립변수의 변화에 따른 종속변수의 변화량을 가장 근사한 값으로 나타내는 방정식이기 때문에 기울기가 같더라도 측정된 값들의 분포는 달라 질 수 있다.

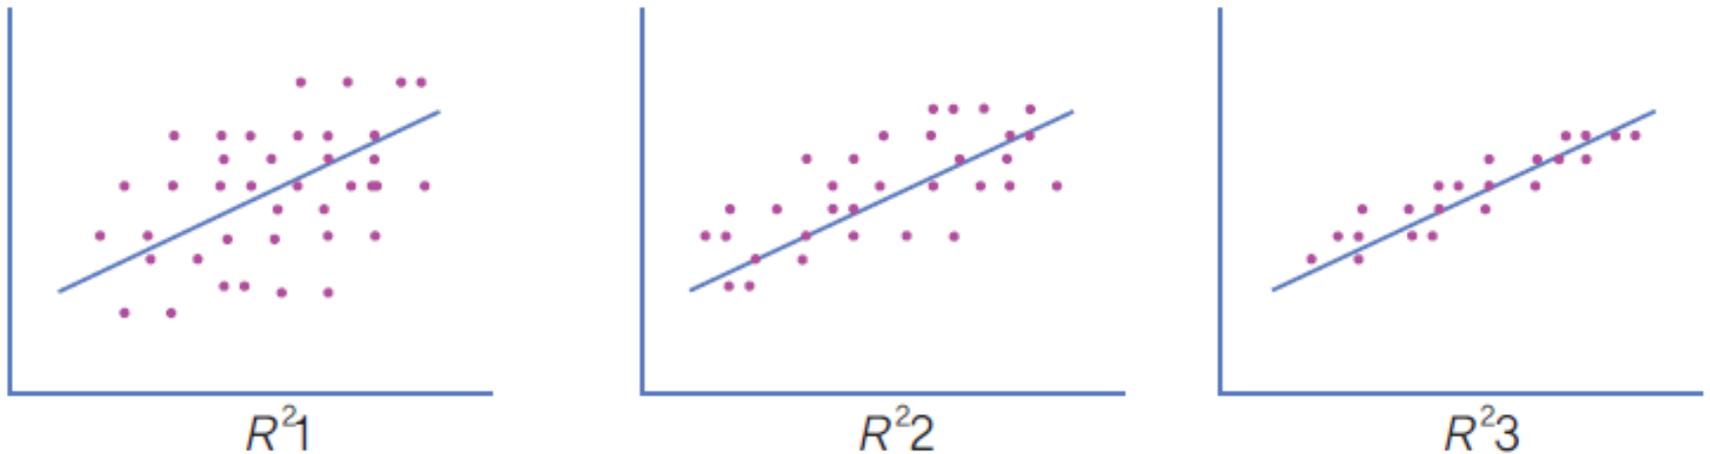


그림 14-1. 측정값들의 분포에 따른 변수의 설명력

⑤ 종속변수에 대하여 독립변수들이 어느 정도 설명할 수 있는가를 파악해야 하는데 이를 변수의 설명력이라 하고 상관계수의 제곱으로 표현하며 이를 결정계수(R^2)

종속변수에 대한 독립변수들이 갖는 변수의 설명력의 크기는 $R^2_3 > R^2_2 > R^2_1$ 순이다.

단순회귀 분석일 때

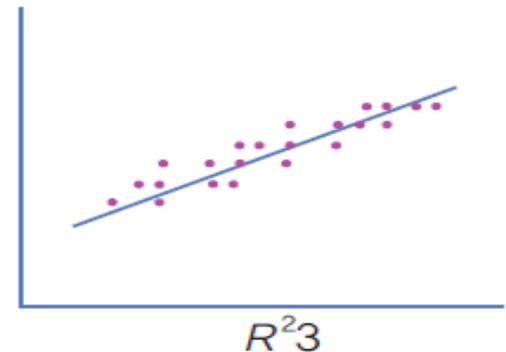
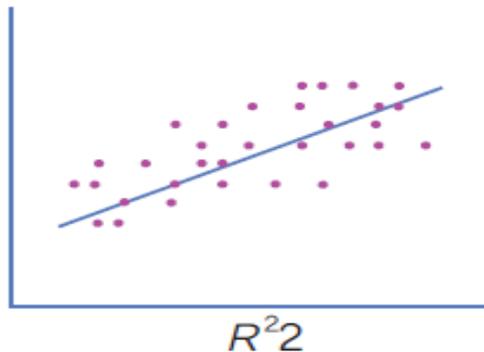
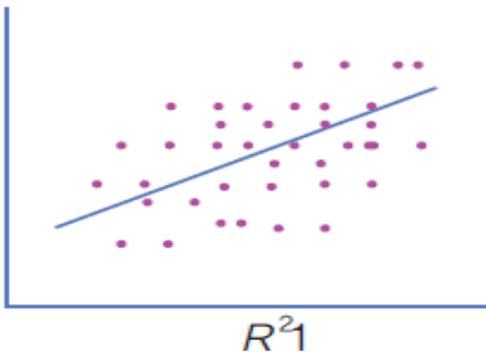
영가설(H_0): $\beta_1 = 0$

대립가설(H_A): $\beta_1 \neq 0$,

다중회귀분석일 때

영가설(H_0): $\beta_1 = \beta_2 = \beta_3 = \dots = 0$

대립가설(H_A): 모든 회귀계수가 0은 아니다.



회귀분석의 가설

H_0 : 독립변수 X 가 Y 에 영향을 주지 않는다.

H_1 : 독립변수 X 가 Y 에 영향을 준다.

회귀분석, 결과 분석하기

① R^2 의 의미

R^2 를 적합도의 척도로 사용할 수 있다는 것은 알았지만 R^2 의 정확한 의미는 무엇일까? (R^2 는 추정된 직선이 자료를 얼마나 잘 설명할 수 있는지를 나타낸다.)

두 변수간에 회귀방정식을 구했다고 하자. $R^2 = 0$ 라면 기울기는 0이다. R^2 가 1이라 하면 오차가 0이다. 만약 0.52라면 52%를 설명한다고 할 수 있다.

② F값의 이해

- F값은 모형 적합도를 나타냄

P값이 0.05보다 작으면 이 모형이 적합하다고 할 수 있다.

P값이 0,05보다 크면 이 모형을 부적합하다고 할 수 있다.

R제곱과 F값

R제곱 : 독립변수가 종속변수의 몇 퍼센트인가를 설명하는 수치

F값 : 회귀식의 적합도 ($p < 0.05$ 보다 작아야 회귀식이 유의미함)

③ B값과 β 값

- B는 적대적 영향력의 크기를 알려주며 표준화되지 않는 영향력을 판단할 때 사용하고,

β 는 이 영향력의 상대적인 차이를 비교할 때 사용합니다.

B와 β

B : 비표준화 계수

절대적인 영향력의 크기

β : 표준화 회귀계수

상대적인 영향력의 크기,

종속변수에 가장 큰 영향을 미치는 변수가 무엇인가를 판단할 때 활용

④ 공선성

- **공선성**은 한 독립변수의 값이 증가할 때 다른 독립변수의 값이 증가, 감소하는 현상을 말한다. 이 말은 독립변수 서로가 상관관계가 있어 독립적이지 않고 종속적이라는 말이기에 회귀분석을 하지 말아야 한다.
- 체크하기 위한 것이 분산팽창계수(VIF)와 공차한계(공차)이다.
- VIF의 수치 중 10 이상의 항목과 공차의 수치 중 0.1 이하의 항목은 버리거나 요인분석을 통해 항목을 합쳐 다시 회귀분석을 해야 한다. 즉 이 항목은 종속적이라는 말.

⑤ 잔차의 독립성 확인

- Durbin-Watson 통계량으로 확인 (0에 가까우면 음의 상관; 4에 가까우면 양의 상관- 결국 0과 4에 가깝지 않아야 한다)
- 2전 후값을 갖을 때

단순회귀분석의 과정

회귀방정식을 구하는 것이 끝이 아니라 검정이 필요하다.

((단순회귀직선의 적합도 검정))

가설의 설정 $Y_i = \beta_0 + \beta_1 X_i$

영가설 : $\beta_1 = 0$

대립가설 : $\beta_1 \neq 0$

H_0 : 독립변수 X가 Y에 영향을 주지 않는다.

H_1 : 독립변수 X가 Y에 영향을 준다.

검정통계량은 F값으로 본다.

회귀직선의 진단 시 고려해야 할 것

① 독립변수들 간의 다중 공선성- 독립변수간에 상관이 높은 것을 피한다

② 이상값에 대한 점검

Cook의 통계량의 값이 1.0이상이면 이상점으로 간주.

③ 잔차(residual) – 등분산성, 독립성, 정규성

잔차의 독립성의 경우, **Durbin-Watson** 통계량으로 확인 (0에 가까우면 음의 상관; 4에 가까우면 양의 상관- 결국 0과 4에 가깝지 않아야 한다)

잔차의 정규성의 경우 – 정규확률도표를 그려 확인.

(2) 잔차의 분석

- 잔차는 독립성, 정규성, 등분산성을 만족해야 하며, 그 검정을 위해 아래 그래프를 그릴 수 있다. 회귀모형을 이용한 추론이나 예측이 타당성을 얻으려면 회귀모형의 가정들을 만족해야 한다. Y_i 혹은 X_i 에 대한 잔차 e_i 의 산점도를 이용하여 회귀모형의 가정에 대한 검토를 할 수 있다.

B병원의 중환자실 환자 20명 중에서 인공호흡을 하는 사람은 15명.

흡입된 산소의 분률과 ABGA로 측정된 동맥혈 산소 분압을 기록한 자료이다.

회귀분석의 가설

H_0 : 독립변수 X가 Y에 영향을 주지 않는다.

H_1 : 독립변수 X가 Y에 영향을 준다.

통계청 자료 분석을 통해 각 각 대입

가계지출 = f(소비지출 + 식료품 + 외식 + 주거비 + 가구가사 + 광열
수도 + 피복 및 신발)



① 분석 → ② 회귀분석 → ③ 선형

파일(F) 편집(E) 보기(V) 데이터(D) 변환(1) 분석(A) 그래프(G) 유틸리티(U) 창(W) 도움말(H)

보고서(P) >
기술통계량(E) >
표 >
평균 비교(M) >
일반선형모형(G) >
일반화 선형 모형(Z) >
혼합 모형(O) >
상관분석(C) >
② 회귀분석(R) >
로그선형분석(O) >
분류분석(Y) >
차원 감소(D) >
척도(A) >
비모수 검정(N) >
예측(T) >
생존확률(S) >
다중응답(U) >
결측값 분석(V)... >
다중 대입(T) >
품질 관리(Q) >
ROC 곡선(V)... >

비 066.00
광열수도 81761.00
가구가사 72013.00
피복및신발 105541.00

1 2081783.00 1802216.00 4680

2 2143506.00 1850740.00 5064

3 2056869.00 1778958.00 4897

4 2227033.00 1950411.00 4688

5 2161564.00 1868896.00 4915

6 2256129.00 1940181.00 5377

7 2251200.00 1931914.00 5404

8 2443699.00 2106688.00 5125

9 2261809.00 1930728.00 5249

10 2388199.00 2040292.00 5800

11 2347822.00 1995135.00 5615

12 2541785.00 2186805.00 5300

13 2352358.00 1992908.00 5326

14 2505576.00 2107593.00 5702

15 2433977.00 2080115.00 5733

16 2656286.00 2269535.00 5419

17 2463888.00 2082998.00 5349

18 2564084.00 2117498.00 5568

19

선형(L)... ③ 87133.00

곡선추정(C)... 123261.00

일부 최소제곱(S)... 103468.00

미분형 로지스틱(G)... 111659.00

다항 로지스틱(M)... 86475.00

순서(D)... 118712.00

프로빗(P)... 105509.00

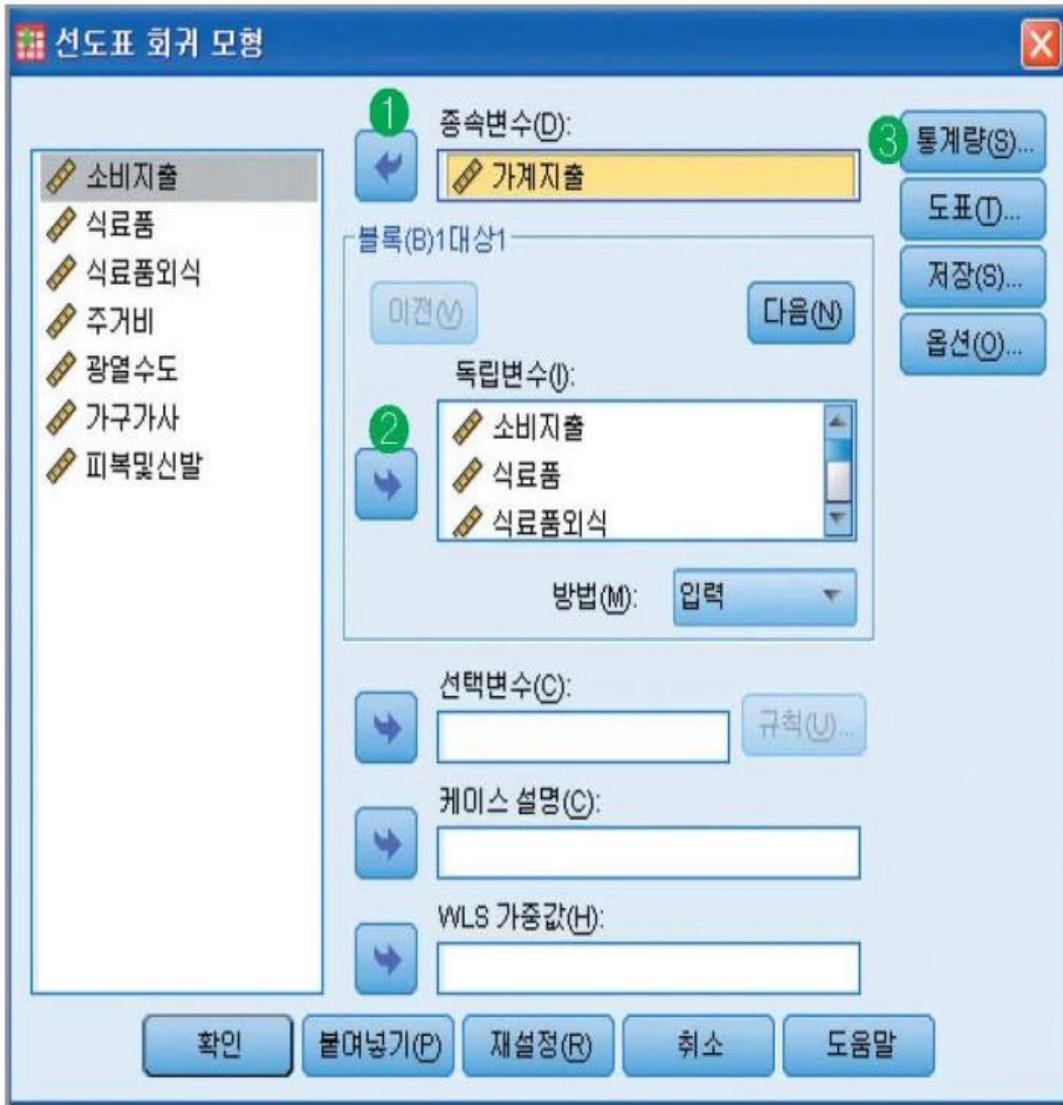
비선형(N)... 116700.00

가중추정(W)... 90649.00

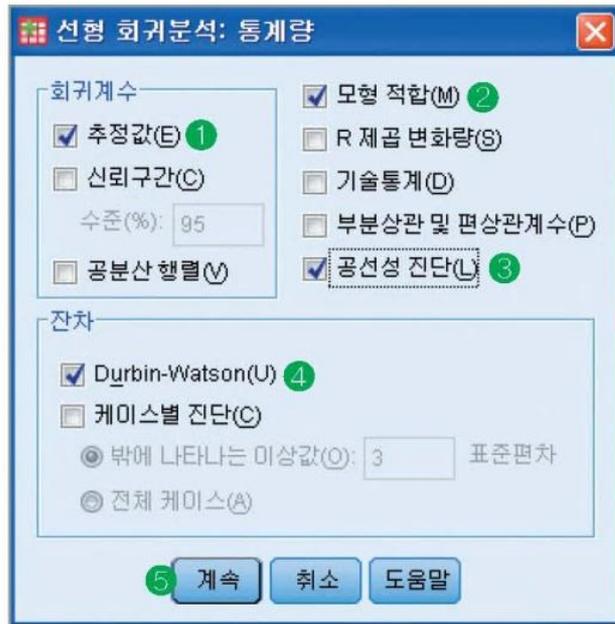
2-단계 최소제곱(2)... 130484.00

최적화 척도법(CATREG)... 115014.00

93930.00



- ① 가계지출은 종속변수
- ② 소비지출, 식료품, 외식, 주거비, 가구가사, 광열수도, 피복 및 신발은 독립변수에 삽입
- ③ 통계량 클릭



- ① 추정값 체크
- ② 모형 적합 체크
- ③ 공선성 진단 체크
- ④ Durbin-Watson 체크
- ⑤ 계속 클릭
- ⑥ 도표 클릭



- ① y축으로 이동
- ② x축으로 이동
- ③ 히스토그램 체크
- ④ 정규확률도표 체크
- ⑤ 계속 클릭

결과 보고서 분석

모형 요약^b

모형	R	R 제곱	수정된 R 제곱	추정값의 표준오차	Durbin-Watson
1	.998 ^a	.996	.993	14722.78596	2.230

a. 예측값: (상수), 피복 및 신발, 식료품, 광열수도, 주거비, 식료품외식, 가구가사, 소비지출

b. 종속변수: 가계지출

R 제곱은 결정계수(설명력)로 독립변수의 변화에 의해 설명될 수 있는 종속변수의 변화량을 나타낸다.



R 제곱은 회귀선의 기여율이다. 0에서 1 사이에 존재하며, 0에 가까우면 회귀분석의 유용 가치가 없어지며, 1에 가까울수록 회귀분석의 유용 가치가 높아진다.

Durbin-Watson 계수는 자동 상관에 대한 검정 통계량이다.

자동 상관은 관측 자료에 오류가 포함되는 것을 말한다.



Durbin-Watson 계수는 0에서 4 사이의 값이 나타나는데, 2에 가까우면 자동 상관을 무시해도 된다.

분산분석^b

모형	제공합	자유도	평균 제공	F	유의확률
1 회귀 모형	5.048E11	7	7.211E10	332.660	.000 ^a
잔차	2.168E9	10	2.168E8		
합계	5.069E11	17			

a. 예측값: (상수), 피복 및 신발, 식료품, 광열수도, 주거비, 식료품외식, 가구가사, 소비지출

b. 종속변수: 가계지출

- 분산분석은 회귀모형이 유의성을 검정하는 분석으로 가설은 다음과 같다.

H_0 : 회귀모형이 필요하지 않다.

H_1 : 회귀모형이 필요하다.

유의 확률이 0.05보다 작아야 회귀모형이 이룬다.

계수^a

모형	비표준화 계수		표준화 계수	t	유의확률	공선성 통계량	
	B	표준오차	베타			공차	VIF
1 (상수)	-284757.485	112678.805		-2.527	.030		
소비지출	1.212	.112	.936	10.777	.000	.057	17.635
식료품	-.203	.316	-.040	-.642	.535	.111	9.022
식료품외식	.267	.355	.034	.754	.468	.206	4.854
주거비	3.332	1.575	.097	2.115	.061	.203	4.936
광열수도	-.272	.492	-.043	-.552	.593	.070	14.265
가구가사	1.180	1.205	.057	.980	.350	.128	7.807
피복 및 신발	-.502	.605	-.040	-.830	.426	.188	5.309

a. 종속변수: 가계지출

회귀계수(비표준화 계수, B)는 독립변수와 종속변수와의 관계를 설명한다.



표준화계수(베타)는 독립변수가 종속변수에 미치는 상대적 영향력으로, 독립변수의 절대값이 가장 큰 변수가 가장 많은 영향을 미친다.

- VIF의 수치 중 10 이상의 항목과 공차의 수치 중 0.1 이하의 항목은 버리거나 요인분석을 통해 항목을 합쳐 다시 회귀분석을 해야 한다. 즉 이 항목은 종속적이라는 말.
- 이 연구에서 소비지출과 광열수도는 공차한계 0.1이므로 제외하고 다시 회귀분석을 해야 한다.

- 방정식 구성

$$Y(\text{가계지출}) = -284757.485(\text{상수}) + 1.212(\text{소비지출}) + \text{오차}$$

- $Y(\text{가계지출}) = -284757.485(\text{상수}) + 1.212(\text{소비지출}) + \text{오차}$

여기에서 통계학적인 의미에서 회귀계수가 양의 값인 소비지출이 1원 증가 할 수록 가계지출은 1.212원이 증가한다.

여기에서 유의확률 중 0.05이하는 소비지출뿐이다. 하지만 소비지출은 공차한계가 0.1이하이므로 제외하거나 요인분석을 통해 종속적인 요인을 합해 다시 회귀분석을 해야 한다.

책에서 예제



Tip

회귀분석에 사용되는 변수들 가운데 연속형이 아닌 명목형 즉 범주형 변수도 포함할 수 있다. 다만 자료의 값이 0과 1로 표현된 가변수로 치환된 경우에만 해당한다. 하지만 이 책에서는 가변수가 포함되지 않는 분석만을 예시로 보여준다.



예시

연령과 혈중 콜레스테롤, 허리둘레, 체질량지수, 중성지방이 수축기 혈압에 어떤 영향을 주는지 상관분석에서 활용 한 데이터를 이용하여 SPSS 프로그램을 이용하여 회귀분석을 실습해보도록 하자.

(1) 통계학적 가설

H_0 : 연령과 허리둘레, 체질량 지수, 혈중 콜레스테롤 수치, 중성지방은 수축기 혈압에 영향을 주지 않는다.

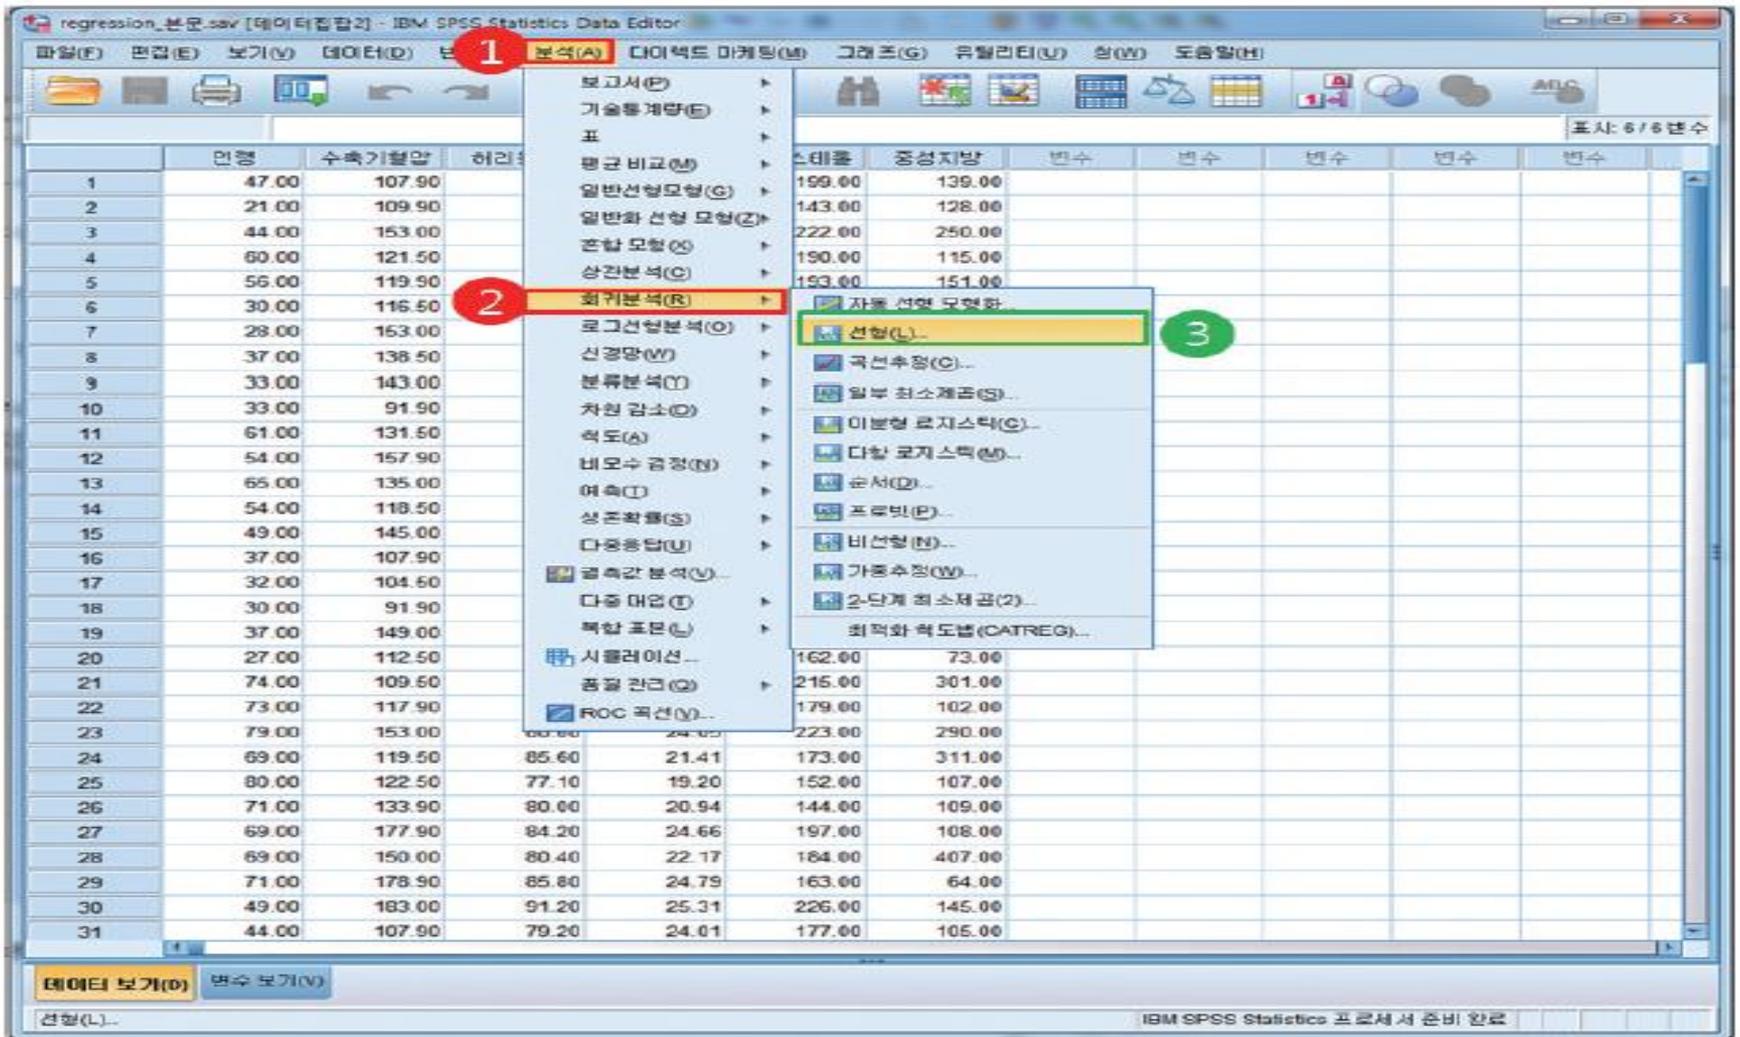
H_A : 연령과 허리둘레, 체질량 지수, 혈중 콜레스테롤 수치, 중성지방은 수축기 혈압에 영향을 줄 것이다.

(2) 자료 입력하기

자료의 입력은 모두 연속형 변수로 입력한다

(3) 회귀분석 대화상자 열기

메뉴에서 ①[분석(A)] → ②[회귀분석(R)] → ③[선형(L)]를 클릭한다.



(4) 변수 옮기기

대화상자에서 종속변수(D)에 수축기 혈압을 넣고, 독립변수(I)에 연령, 허리 둘레, 체질량 지수, 콜레스테롤, 중성지방을 입력한다.

(5) 분석 실행하기

방법(M)에서 유의성의 세기에 관계없이 모든 변수들이 종속변수에 미치는 영향을 한 번에 보고 싶다면 입력을, 유의성이 큰 변수들을 우선으로 하여 순차적인 모형을 만들고 싶다면 단계선택으로 바꿔주면 된다. [확인]을 클릭한다.

(5) 분석 실행하기



(6) 결과 해석하기

진입/제거된 변수^a

모형	진입된 변수	제거된 변수	방법
1	중성지방, 연령, 콜레스테롤, 체질량지수, 허리둘레 ^b		입력

a. 종속변수: 수축기혈압

b. 요청된 모든 변수가 입력되었습니다.

모형요약

모형	R	R 제곱	수정된 R의 제곱	추정값의 표준오차
1	.615 ^a	.378	.341	18.23995

a. 예측값: (상수), 중성지방, 연령, 콜레스테롤, 체질량지수, 허리둘레

(6) 결과 해석하기

수축기 혈압에 영향을 주는 변수들을 직선회귀 방정식으로 표현하는 방법

$$\begin{aligned} \text{수축기 혈압} = & 29.2171 + (0.321 \times \text{연령}) - (0.003 \times \text{허리둘레}) + (1.637 \times \text{체질량 지수}) \\ & + (0.180 \times \text{콜레스테롤}) + (0.072 \times \text{중성지방}) \end{aligned}$$

(6) 결과 해석하기

분산분석^a

모형	제공합	자유도	평균 제공	F	유의확률
1 회귀모형	17000.672	5	3400.134	10.220	.000 ^b
잔차	27946.449	84	332.696		
합계	44947.121	89			

a. 종속변수: 수축기혈압

b. 예측값: (상수), 중성지방, 연령, 콜레스테롤, 체질량지수, 허리둘레

계수^a

모형	비표준화 계수		표준화계수	t	유의확률
	B	표준오차	베타		
1 (상수)	29.217	23.793		1.228	.223
연령	.321	.135	.238	2.371	.020
허리둘레	-.003	.494	-.001	-.006	.995
체질량지수	1.637	1.330	.196	1.231	.222
콜레스테롤	.180	.070	.241	2.549	.013
중성지방	.072	.031	.241	2.348	.021

a. 종속변수: 수축기혈압



여기서 돋보기!

논문에 실제로 적용하기

다른 변수를 통제한 상태에서 수축기 혈압은 연령이 한 살 증가할 때마다 0.321 mmHg 씩 증가하였고, 콜레스테롤 이 한 단위 증가할 때마다 0.180 mmHg씩 증가하였으며, 중성지방이 한 단위 증가할 때마다 0.072 mmHg씩 증가하였고 통계적으로 유의하였다($p,0.05$). 하지만 체질량 지수와 허리둘레는 수축기 혈압에 대해 유의한 변수로 작용하지 못하였다. 이 회귀식에서 독립변수들이 수축기 혈압에 대하여 갖는 변수의 설명력은 34.1%였으며 분석 결과는 다음과 같다.

표 14-1. 수축기 혈압에 영향을 주는 요인에 대한 다중회귀 분석

변수	B	표준오차	베타	t	p값
(상수)	29.217	23.793		1.228	.223
연령	.321	.135	.238	2.371	.020
허리둘레	-.003	.494	-.001	-.006	.995
체질량지수	1.637	1.330	.196	1.231	.222
콜레스테롤	.180	.070	.241	2.549	.013
중성지방	.072	.031	.241	2.348	.021

종속변수: 수축기혈압

$R^2: 0.341$

다음의 자료는 식도암으로 사망한 사람들의 진단시 병기(Stage)와 생존개월수 (Month)를 나타낸 것이다. 다음 자료를 이용해 진단시 병기와 생존개월 수의 회귀방정식을 세워보자

Index	1	2	3	4	5
Stage	1	2	2	2	3
Month	50	48	37	35	43
Index	6	7	8	9	10
Stage	3	3	4	4	4
Month	22	19	15	7	5

모형 요약^b

모형	R	R 제곱	수정된 R 제곱	추정값의 표준오차	등계량 변화량					Durbin-Watson
					R 제곱 변화량	F 변화량	df1	df2	유의확률 F 변화량	
1	.884 ^a	.781	.754	8.258	.781	28.589	1	8	.001	2.554

a. 예측값: (상수), Stage

b. 종속변수: Month

1. 회귀분석에서 귀한 회귀선의 설명력 = 0.781로 상당히 높다

분산분석^a

모형		제곱합	자유도	평균 제곱	F	유의확률
1	회귀 모형	1949.400	1	1949.400	28.589	.001 ^b
	잔차	545.500	8	68.188		
	합계	2494.900	9			

a. 종속변수: Month

b. 예측값: (상수), Stage

2. 유의성 검정으로 0.05보다 작음으로 회귀직선은 유의하다.

계수²

모형	비표준화 계수		표준화 계수	t	유의확률	공선성 통계량	
	B	표준오차	베타			공차	VIF
1 (상수)	68.000	7.906		8.601	.000		
Stage	-14.250	2.665	-.884	-5.347	.001	1.000	1.000

a. 종속변수: Month

3. 유의확률이 0.001임으로 stage는 month를 설명해주는 유의한 변수이고 회귀식은 비표준화 계수의 값을 읽어서 $\text{month} = 68 - 14.25 \times \text{stage}$

표준화 계수는 모든 변수값을 평균 0, 표준편차를 1로 맞춘 값.

독립변수가 여러 개거나 변수간의 단위가 다를 때 변수의 영향력을 비교할 수 있다.

표준화계수의 값이 최대인 변수가 가장 영향력이 큰변수이다.