

# Multipel regresjon

Her utvider vi perspektivet for enkel lineær regresjon til også å omfatte **flere forklaringsvariable**  $x_1, x_2, \dots, x_p$ .

Det er fortsatt en responsvariabel  $y$ .

Måten dette gjøres på er nokså direkte. Prediktoren utvides med flere lineære ledd, et for hver forklaringsvariabel.

Men det oppstår en del nye problemerstillinger. Vi kommer til å konsentrere oss om det som er felles med enkel lineær regresjon.

# Eksempel: Multippel regresjon

**Lungefunksjon**  $y$  hos barn kan f.eks. målt med  $FEV_1$  (Forced expiratory volum i liter etter å blåse i ett sekund).

Lungefunksjon kan avhenge av bl.a.

- **høyde** i cm ( $x_1$ )
- **vekt** i kg ( $x_2$ )
- **alder** i år ( $x_3$ )
- **kjønn** ( $x_4 = 0$  for jenter,  $x_4 = 1$  for gutter)

og gjerne alle variablene **samtidig!**

# Formål med multippel regresjon

- Fenomener er typisk **multifaktorielle**, respons  $y$  har ofte sammenheng med flere forklaringsvariable  $x_1, x_2, \dots, x_p$ .
- **Variasjonen** i  $y$  gitt flere  $x$ -er blir **mindre** enn den tilsvarende i enkel lineær regresjon. Vi kan få mer **presise** estimater og prediksjoner.
- Det kan være **konfunderende** (lurkende) variable. Hvis disse er observert kan vi ta hensyn til det i en multippel regresjon.

I enkel lineær regresjon beskrev linja

$$\mu_y = \beta_0 + \beta_1 x$$

hvordan forventningen til responsvariabelen avhenger av forklaringsvariabelen  $x$ . Det nye i multippel regresjon er at forventningen avhenger av  $p$  forklaringsvariable og har formen

$$\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

Dette kalles **populasjons regresjonsligningen**.

Som i enkel lineær regresjon kan vi for hver hver fast, fiksert verdsett av forklaringsvariablene  $x_1, x_2, \dots, x_p$  tenke oss at finns en **subpopulasjon** av responser. Hver subpopulasjonen karakteriseres ved at fordelingene har en bestemt forventning. Forøvrig er fordelingene like. Spesielt har de samme standardavvik  $\sigma$ .

**Eksempel:** Suksess i college.

Respons  $y$ : GPA, kumulativ «grade point average» etter tre semestre

Forklaringsvariable:  $x_1$  karakter i matematikk på videregående, HSM

$x_2$  karakter i naturfag på videregående, HSS


$x_3$  karakter i engelsk på videregående, HSE

som kan gi modeller av typen

$$\mu_{GPA} = \beta_0 + \beta_1 HSM + \beta_2 HSS + \beta_3 HSE$$

**Subpopulasjon**, for enkel lineær regresjon.

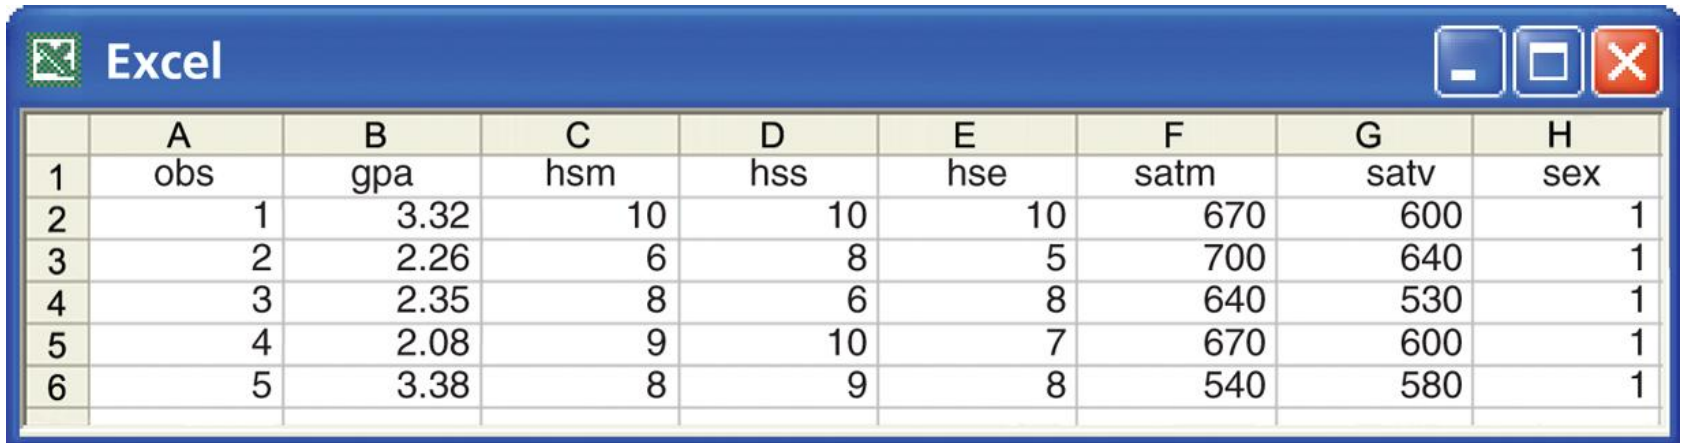
For **multippel regresjon** tenker vi oss tilsvarende subpopulasjoner for alle mulige kombinasjoner av forklaringsvariable.



Også her er det hensiktsmessig å organisere observasjonenen i en **datamatrise** som kan beskrives ved

Enhet	Respons	Forklaringsvariable		
		$x_1$	...	$x_p$
1	$y_1$	$x_{11}$	...	$x_{1p}$
2	$y_2$	$x_{21}$	...	$x_{2p}$
	...			
n	$y_n$	$x_{n1}$	...	$x_{np}$

I en statistikkpakke / regneark vil dette f.eks. se slik ut:



The image shows a screenshot of an Excel spreadsheet window. The window title is "Excel". The spreadsheet contains a table with 8 columns (A-H) and 6 rows (1-6). The columns are labeled: A: obs, B: gpa, C: hsm, D: hss, E: hse, F: satm, G: satv, H: sex. The data is as follows:

	A	B	C	D	E	F	G	H
1	obs	gpa	hsm	hss	hse	satm	satv	sex
2	1	3.32	10	10	10	670	600	1
3	2	2.26	6	8	5	700	640	1
4	3	2.35	8	6	8	640	530	1
5	4	2.08	9	10	7	670	600	1
6	5	3.38	8	9	8	540	580	1

(Tallene svarer ikke helt til utgave 8 i læreboka, de er hentet fra utgave 7)



## Minitab-utskrift for GPA-data (editert)

### Model Summary

S	R-sq	R-sq (adj)	R-sq (pred)
0,726103	22,77%	21,19%	18,01%

### Coefficients

Term	Coef	SE Coef	T-Value	P-Value
Constant	0,069	0,454	0,15	0,879
HSM	0,1232	0,0549	2,25	0,026
HSS	0,1361	0,0700	1,95	0,054
HSE	0,0585	0,0654	0,89	0,373

### Regression Equation

GPA = 0,069 + 0,1232 HSM + 0,1361 HSS + 0,0585 HSE

## Uttrykket

$$\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

beskriver hvordan forventningen varierer med de ulike forklaringsvariablene.

Men **merk**:

- Koeffisienten  $\beta_0$  er forventningen når alle forklaringsvariablene er lik null. Denne er **enda mindre** interessant enn ved enkel lineær regresjon.
- Tolkningen av de andre parametrene  $\beta_j$  er at forventningen endres med denne verdien når  $x_j$  endres med **en enhet** (fra  $x_j$  til  $x_j + 1$ ) samtidig som at alle de andre forklaringsvariablene holdes **konstant**.

I data-eksempelet fikk vi estimert **regesjonslinje**

$$\text{GPA} = 0,069 + 0,1232 \text{ HSM} + 0,1361 \text{ HSS} + 0,0585 \text{ HSE}$$

Dermed er  $b_0 = 0.069$  som er estimert GPA for studenter med  $\text{HSM} = \text{HSS} = \text{HSE} = 0$ . Det finnes **ingen** studenter med så dårlige karakterer i utvalget.

Videre er  $b_1 = 0.1232$ . Dette betyr at hvis vi sammenligner to studenter med samme HSS og HSE, men med en differans i HSM lik 1, så venter vi at den "beste" studenten fra high-school skal ha 0.1232 bedre GPA.

Tilsvarende er  $b_2 = 0.1361$ . Dermed estimerer vi at den beste av to studenter med lik HSM og HSE, men en differans på 1 for HSS skal score 0.1361 bedre på sin GPA.

Den **statistiske modellen for multippel lineær regresjon** er

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon_i$$

for  $i=1, \dots, n$ . Her er forventningen til responsverdien

$$\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

en lineær funksjon av forklaringsvariablene.

Avvikene  $\epsilon_i$  antas å være uavhengige normalfordelte variable med forventning 0 og standardavvik  $\sigma$ , dvs.  $N(0, \sigma)$ .

Parametrene i modellen er  $\beta_0, \beta_1, \dots, \beta_p$  og  $\sigma$ .

## Antagelsen i multippel lineær regresjon, mer detaljert.

Vi kan mer spesifikt skrive opp modellen i 4 punkter:

- **Linearitet:**  $\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$
- **Uavhengighet:** Gitt x-ene er  $y_1, y_2, \dots, y_n$  (samt  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ ) uavhengige.
- **Konstant varians:** Gitt x-ene har  $y_1, y_2, \dots, y_n$  (samt  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ ) samme standardavvik  $\sigma$ .
- **Normalitet:** Gitt x-ene er  $y_1, y_2, \dots, y_n$  (samt  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ ) normalfordelte

Metoden for å finne estimatorer  $b_0, b_1, \dots, b_p$  for parametrene  $\beta_0, \beta_1, \dots, \beta_p$  er ved **minste kvadraters metode**. Estimert respons for den  $i$ 'te enheten er

$$\hat{y}_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_p x_{ip}$$

Det tilsvarende residualet er som tidligere definert som avviket mellom observert verdi og predikert verdi

$$\begin{aligned} e_i &= \text{observert respons} - \text{predikert respons} \\ &= y_i - \hat{y}_i \\ &= y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip}. \end{aligned}$$

**Minste kvadraters estimatorene** består nå i å velge de b-ene slik at summen av kvadratavvikene minimeres, altså  $(b_0, b_1, b_2, \dots, b_p)$  slik at

$$\sum (y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip})^2$$

blir minst mulig.

Untatt i helt spesielle situasjoner finnes det **ikke enkle formler** for de enkelte  $b_j$ , men det er ikke noe problem å regne dem ut på en datamaskin.

For å estimere (residual) **varians**  $\sigma^2$  bruker vi formelen

$$s^2 = \frac{1}{n-p-1} \sum (y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip})^2$$

altså som et "gjennomsnitt" av kvadrerte residualer og estimat for  $\sigma$  blir som tidligere  $s = \sqrt{s^2}$

Grunnen til at vi deler på  $n-p-1$  i

$$s^2 = \frac{1}{n-p-1} \sum (y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip})^2$$

er at vi har estimert  $p+1$  regresjonsparametre  $(b_0, b_1, b_2, \dots, b_p)$ .

Man kan vise at  $s^2$  dermed vil være **forventningsrett** for  $\sigma^2$ .

Vi sier at vi har brukt  $p+1$  **frihetsgrader** og at vi har  $n-p-1$  frihetsgrader igjen.

Dette er helt tilsvarende enkel lineær regresjon der  $p=1$  og vi brukte  $p+1=2$  til estimeringen og hadde  $n-2$  frihetgrader igjen.



Også tilsvarende enkel lineær regresjon vil vi ved multippel regresjon ha at minste kvadraters estimatorene  $b_j$  alle vil være **forventningsrette**

$$\mu_{b_j} = \beta_j$$

Dessuten kan man beregnes deres **standardfeil**  $SE_j$  (dvs. deres standardavvik). Formlene for disse er kompliserte, men det lett å beregne dem på en datamaskin. De er for øvrig proporsjonale med standardavviket  $s$ .

Videre vil vi ha at  $b_j$  er **normalfordelte** når feilleddene  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  er normalfordelte. Hvis ikke denne egenskapen holder vil likevel estimatorene  $b_j$  være tilnærmet normalfordelte når  $n$  er stor.

Dermed får vi også **t-statistikker**  $t_j = \frac{b_j}{SE_j}$   
som blir t-fordelt med  $n-p-1$  frihetsgrader hvis  $\beta_j = 0$

## Minitab-utskrift for GPA-data (igjen, men med fokus på estimater og standardfeil)

### Model Summary

S	R-sq	R-sq (adj)	R-sq (pred)
0,726103	22,77%	21,19%	18,01%

### Coefficients

Term	Coef	SE Coef	T-Value	P-Value
Constant	0,069	0,454	0,15	0,879
HSM	0,1232	0,0549	2,25	0,026
HSS	0,1361	0,0700	1,95	0,054
HSE	0,0585	0,0654	0,89	0,373

### Regression Equation

GPA = 0,069 + 0,1232 HSM + 0,1361 HSS + 0,0585 HSE

Dette gir resultater som generaliserer det vi har sett:

Et **konfidensintervall** med konfidenskoeffisient lik  $C$  for  $\beta_j$  har grenser

$$b_j \pm t^* SE_{b_j}.$$

Her er  $t^*$  den verdien som gjør at arealet under tetthetskurven til en  $t(n-p-1)$  fordeling mellom  $-t^*$  og  $t^*$  er  $C$ .

## Minitab-utskrift for GPA-data (med konfidensintervall)

Her er  $n=150$  og  $p=3$ , så vi har  $n-p-1 = 146$  frihetsgrader for t-fordelingen og 97.5 persentilen i  $t_{146}$  er  $t^* = 1.976346$

### Coefficients

Term	Coef	SE Coef	95% CI
Constant	0,069	0,454	( -0,827; 0,966)
HSM	0,1232	0,0549	( 0,0148; 0,2317)
HSS	0,1361	0,0700	(-0,0021; 0,2744)
HSE	0,0585	0,0654	(-0,0708; 0,1878)

Vi kan legge merke til at kun et av disse intervallene ikke inneholder verdien null, dermed vil bare parameteren svarende til HSM være signifikant forskjellig fra 0.

For å teste nullhypotesene  $H_0: \beta_j = 0$  benyttes altså t-statistikken

$$t = \frac{b_j}{SE_{b_j}}$$

Når  $H_0: \beta_j = 0$  holder vil denne t-statistikken være trukket fra en T-fordeling med  $n-p-1$  frihetsgrader.

La i det følgende  $T$  være en tilfeldig variabel fra denne fordelingen.

P-verdien for testen vil avhenge av hvilket alternativ vi bruker. Standard er å rapportere P-verdier fra tosidige tester.

P-verdien for  $H_0: \beta_j = 0$  blir

med ensidig alternativ hypotese  $H_a: \beta_j < 0$  :

$$P( T < t )$$

med ensidig alternativ hypotese  $H_a: \beta_j > 0$  :

$$P( T > t )$$

med tosidig alternativ hypotese  $H_a: \beta_j \neq 0$  :

$$2 P( T > | t | )$$

## Minitab-utskrift for GPA-data: Testing

### Coefficients

Term	Coef	SE Coef	T-Value	P-Value
Constant	0,069	0,454	0,15	0,879
HSM	0,1232	0,0549	2,25	0,026
HSS	0,1361	0,0700	1,95	0,054
HSE	0,0585	0,0654	0,89	0,373

I samsvar med hva vi så fra konfidensintervallene var det altså bare HSM som hadde en signifikant sammenheng med GPA, men p-verdien for HSS (0.054) er nær det vanlige signifikanskravet.

Dette er p-verdier ved tosidige tester. Hvis man har bestemt seg for et ensidig alternativ kan man bare dele de oppgitte p-verdiene på 2. (så med ensidig ">" alternativ er også HSS signifikant).

## Estimering av forventet respons og predikasjon av ny verdi $y^*$ .

Akkurat som ved enkel lineær regresjon vil vi være interessert i å estimere, gitt forklaringsvariable  $x_1, x_2, \dots, x_p$ ,

- forventningen til  $y$  med disse forklaringsvariablene

$$\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

- verdien av ny  $y^*$  med de samme forklaringsvariablene

$$y^* = \mu_y + \varepsilon = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon$$

Her er  $\varepsilon$  et feilledd som antas å ha forventning 0 og standardavvik  $\sigma$ , og kanskje er normalfordelt.

For begge størrelsene benytter vi **samme punktestimat**

$$\hat{\mu}_y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p$$

men **variasjonen** må behandles på **ulike** måter.



## Usikkerhet i forventet respons - og i predikert ny verdi $y^*$ :

Standardfeilen  $SE_{\hat{\mu}_y}$  til  $\hat{\mu}_y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p$  avhenger av usikkerheten (varianser og kovarianser) til minste kvadraters estimatorene  $b_0, b_1, b_2, \dots, b_p$  samt av verdiene av forklaringsvariablene  $x_1, x_2, \dots, x_p$ .

Et 95% **konfidensintervall** for  $\hat{\mu}_y$  blir nå gitt ved  $\hat{\mu}_y \pm t^* SE_{\hat{\mu}_y}$  der  $t^*$  er 97.5 persentilen i t-fordelingen med  $n-p-1$  frihetsgrader.

Tilsvarende blir til et 95% **prediksjonsintervall** for ny  $y^*$  gitt ved

$$\hat{\mu}_y \pm t^* SE_{y^*}$$

der  $SE_{y^*}^2 = s^2 + SE_{\hat{\mu}_y}^2$  er estimert varians for ny  $y^*$ .

## Usikkerhet i forventet respons og predikert ny GPA verdi $y^*$ ved ulike verdier av HSM, HSS, HSE

Variable Setting: HSM = 5, HSS = 5, HSE = 5

Fit	SE Fit	95% CI	95% PI
1,659	0,202	(1,259; 2,058)	(0,169; 3,148)

Variable Setting: HSM = 2, HSS = 2, HSE = 2

Fit	SE Fit	95% CI	95% PI
0,705	0,352	(0,009; 1,401)	(-0,890; 2,300) <b>XX</b>

Variable Setting: HSM = 10, HSS = 10, HSE = 10

Fit	SE Fit	95% CI	95% PI
3,248	0,088	(3,074; 3,422)	(1,802; 4,693)

**Merk:** Ved HSM=HSS =HSE får vi negativ nedre grense, **umulig!**  
Tilsvarende øvre grense ved HSM=HSS=HSE=10 større enn 4 (**også umulig!**)

## Forklart andel av varians: $R^2$

Ved enkel lineær regresjon hadde vi at forklart andel av variasjon

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

faktisk var lik korrelasjonskoeffisienten opphøyd i 2 (  $R^2 = r^2$  ).

En så enkel sammenheng har vi ikke ved multippel regresjon. Men vi er fortsatt interessert i å se hvor mye av variasjonen i de opprinnelige dataene som kan forklares ved regresjonen og denne størrelsen er gitt ved den generelle definisjonen, altså

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

som lett kan regnes ut også i dette generaliserte tilfellet.

Kvadratroten  $R = \sqrt{R^2}$  kalles den **multiple korrelasjonskoeffisient**

## Minitab-utskrift for GPA-data: nå uthevd for $R^2$

### Model Summary

S	R-sq	R-sq (adj)	R-sq (pred)
0,726103	22,77%	21,19%	18,01%

### Coefficients

Term	Coef	SE Coef	T-Value	P-Value
Constant	0,069	0,454	0,15	0,879
HSM	0,1232	0,0549	2,25	0,026
HSS	0,1361	0,0700	1,95	0,054
HSE	0,0585	0,0654	0,89	0,373

### Regression Equation

GPA = 0,069 + 0,1232 HSM + 0,1361 HSS + 0,0585 HSE

## Noen egenskaper ved $R^2$

- $0 \leq R^2 \leq 1$
- $R^2$  er kvadratet av korrelasjonskoeffisienten mellom observasjonene  $y_i$  og prediksjonene  $\hat{y}_i$ .
- $R^2$  vil øke (kan **ikke avta**) når vi inkluderer en **ny** forklaringsvariabel
- $R^2$  er større enn kvadrert korrelasjon mellom alle forklaringsvariable  $x_j$  og respons  $y$ .

Siden  $R^2$  vil øke med antall forklaringsvariable også når disse har helt marginal betydning vil den overestimere betydningen av alle forklaringsvariablene. Derfor oppgis også andre varianter av dette målet i statistikkpakker, bl.a.: **Justert** (adjusted) og **predikert**  $R^2$

Model Summary

S	R-sq	R-sq (adj)	R-sq (pred)
0,726103	22,77%	21,19%	18,01%

## Antagelsen i multippel lineær regresjon, punktvis.

- **Linearitet:**  $\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$
- **Uavhengighet:** Gitt x-ene er  $y_1, y_2, \dots, y_n$  (samt  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ ) uavhengige.
- **Konstant varians:** Gitt x-ene har  $y_1, y_2, \dots, y_n$  (samt  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ ) samme standardavvik  $\sigma$ .
- **Normalitet:** Gitt x-ene er  $y_1, y_2, \dots, y_n$  (samt  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ ) normalfordelte

I det følgende skal først se på hvordan antagelsene sjekkes grafisk.

Deretter følger litt diskusjon av konsekvenser og mulige forbedringer.

Linearitet:  $\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$

De to vanligste plottene for å sjekke om lineariteten holder er

- Plott **residualer mot predikerte verdier**
- Plott **residualene mot hver av forklaringsvariablene**

Hvis man ser et **mønster** (f.eks. først positive residualer, deretter negative og så til slutt positive residualer igjen) tyder dette på avvik fra linearitet.

Merk: For enkel lineær regresjon er det samme form på disse plottene – siden predikert verdi er en lineærtransformasjon av forklaringsvariablen.


På neste side er det satt inn

- Plott av residualer mot predikerte verdier (oppe til høyre)
- Plott av residualer mot HSM (oppe til venstre)
- Plott av residualer mot HSS (nede til høyre)
- Plott av residualer mot HSE (nede til venstre)

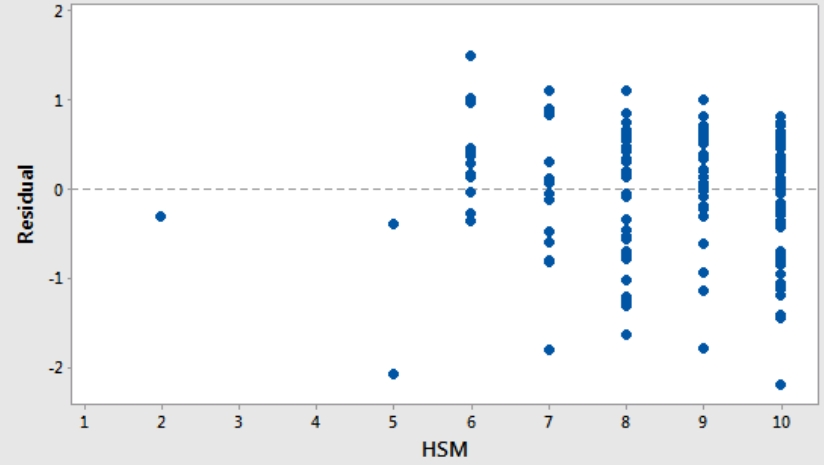
Her er det ikke klare avvik fra linearitet.




**Versus Fits**  
(response is GPA)



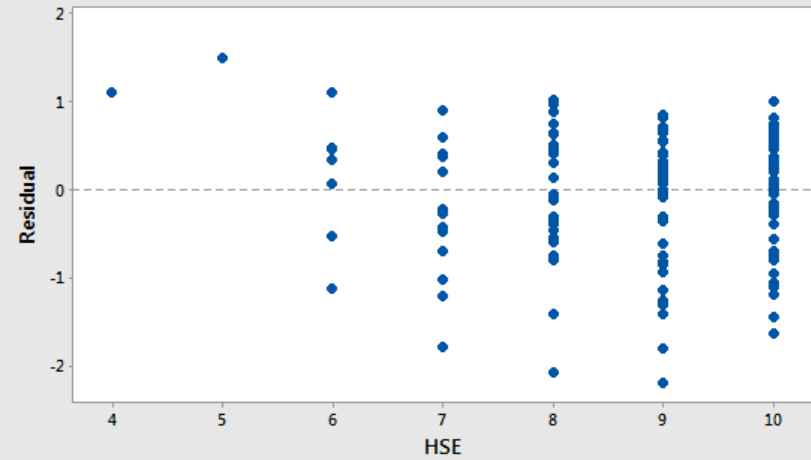
**Residuals Versus HSM**  
(response is GPA)



**Residuals Versus HSS**  
(response is GPA)



**Residuals Versus HSE**  
(response is GPA)




## Uavhengighet:

Hvis dataene er hentet inn i en rekkefølge er det naturlig å plote **residualer mot observasjonsnummer**.

Igjen, **mønstre** indikerer avhengighet.

Også andre typer avhengigheter som innen familier, skoleklasser e.l. kan oppdages: F.eks. hvis residualene innen en klasse systematisk nesten alle er positive.

Men: i mange situasjoner er det ikke mulig å sjekke dette, f.eks. ved GPA-dataene. For illustrasjonens skyld tar ser vi likevel på et plott av residualene mot ordning.




## Konstant varians:

- Plott **residualer mot predikerte verdier**
- Plott **absoluttverdi av residualene mot predikerte verdier**

Hvis man ser et **mønster**, f.eks. en "vifteform" i residualen, dvs. stadig større spredning er det grunn til å tro at antagelsen ikke holder.

På neste side gjentar vi plottet residualer mot predikerte verdier for GPA-dataene. Det er ikke opplagt at det er økende (eller avtagende) variasjon med de predikerte verdiene.

**Versus Fits**  
(response is GPA)




## Normalitet:

- Normalplott av residualene
- Histogram over residualene


Disse plottene skal helst indikere normalfordeling.

I plottene på neste side for GPA-dataene ser vi klare avvik fra normalitetsantagelsen, men det er **ingen** opplagte **outliere**.


Normal Probability Plot  
(response is GPA)



Histogram  
(response is GPA)



Til sammenligning histogrammet over GPA  
(det ligner litt på histogrammet over residualene. Dette siden vi  
forklarer så lite)





## Konsekvenser av avvik fra antagelsene i multippel lineær regresjon.

- **Linearitet:** Modellen er gal og hvis avvikene er markante **må** dette rettes opp!
- **Uavhengighet:** Standardfeil kan bli gale. Dette vil medføre at **inferens** (konf.int/tester) kan bli gale. Men estimatene er likevel OK.
- **Konstant varians:** Standardfeil kan bli gale. Dette vil medføre at **inferens** (konf.int/tester) blir gale. Men estimatene er likevel OK.
- **Normalitet:** Vi har ikke lenger at teststatistikker etc. er t-fordelt. Men dette er ikke kritisk hvis utvalget ( $n$ ) er stort såsant det ikke er outliere.

## Forbedring av lineær regresjonsmodeller, **Linearitet**.

Hvis linearitetsantagelsen  $\mu_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$  svikter kan man prøve bl.a.

- Transformer x-er (f.eks. log-trans.).
- Innfør et nytt ledd  $\beta_{p+1} x_j^2$  i tillegg til  $\beta_j x_j$  (polynomiell regresjon).
- Avansert: glattingsteknikker
- Transformer y-er

## Antagelsen i multippel lineær regresjon, korreksjon.

- **Uavhengighet:** Hvis gruppene er av avhengige enheter er store kan man innføre variable som angir gruppen.
- **Konstant varians:** Transformer y-ene
- **Normalitet:** Sjekk outliere

# Eksperimenter vs. observasjonelle studier

## Planlagte studier – Eksperimenter

- Kan velge verdiene av forklaringsvariablene
- F.eks. slik at de er ukorrelerte
- Dette har en rekke fordeler i multippel regresjon

## Observasjonelle studier

- Må ta de verdiene av forklaringsvariablene man observerer
- Typisk blir de korrelerte
- Må håndtere denne kolineariteten

## Eks: GPA-dataene

**Dette er en observasjonelle studie!**

Ser at det er ganske store korrelasjoner mellom HSM, HSS og HSE:

**Correlation: GPA; HSM; HSS; HSE**

	GPA	HSM	HSS
HSM	0,420 0,000		
HSS	0,443 0,000	0,670 0,000	
HSE	0,359 0,000	0,485 0,000	0,695 0,000

Cell Contents: Pearson correlation  
P-Value

For disse dataene er enkle lineære langt på vei like informative!

### Regression Analysis: GPA versus HSM

S	R-sq	R-sq(adj)	R-sq(pred)
0,744866	17,62%	17,06%	15,31%

Regression Equation

GPA = 0,825 + 0,2349 HSM

### Regression Analysis: GPA versus HSS

S	R-sq	R-sq(adj)	R-sq(pred)
0,735841	19,60%	19,06%	17,35%

Regression Equation

GPA = 0,558 + 0,2596 HSS

### Regression Analysis: GPA versus HSE

S	R-sq	R-sq(adj)	R-sq(pred)
0,766027	12,87%	12,28%	10,14%

Regression Equation

GPA = 0,795 + 0,2318 HSE

Grunnen er at HSM, HSS og HSE her inneholder essensielt den **samme informasjonen** og det er ikke så mye ekstra informasjon å se på alle 3 samtidig!

Det er likevel litt å hente å bruke en modell bare med HSM og HSS:

S	R-sq	R-sq(adj)	R-sq(pred)
0,725607	22,35%	21,29%	19,23%

#### Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	0,257	0,402	0,64	0,524	
HSM	0,1250	0,0548	2,28	0,024	1,81
HSS	0,1718	0,0574	2,99	0,003	1,81

#### Regression Equation

GPA = 0,257 + 0,1250 HSM + 0,1718 HSS

Et annet poeng: Minste kvadraters estimatene er veldig forskjellige i de ulike modellene

$$\text{GPA} = 0,825 + 0,2349 \text{ HSM}$$

$$\text{GPA} = 0,558 + 0,2596 \text{ HSS}$$

$$\text{GPA} = 0,795 + 0,2318 \text{ HSE}$$

$$\text{GPA} = 0,257 + 0,1250 \text{ HSM} + 0,1718 \text{ HSS}$$

$$\text{GPA} = 0,069 + 0,1232 \text{ HSM} + 0,1361 \text{ HSS} + 0,0585 \text{ HSE}$$

Spesielt gjelder dette de enkle lineære regresjonene.

Grunnen er det som er av effekt i f.eks. HSS og HSE forplantes over i HSM i henhold til korrelasjonen mellom forklaringsvariablene når HSS og HSE ikke er med i modellen.