


Kompendium i statistik

VARIANS- OCH KOVARIANSANALYS



Allan Svensson

INNEHÅLLSFÖRTECKNING

I	EN-VÄGS VARIANSANALYS	1
	1. Introduktion	
	2. En jämförelse mellan en- och två-vägs varians- analys	2
	3. Inom- och mellangrupsvariansomått	4
	4. Beräkningsformler vid en-vägs variansanalys	12
	5. Skillnader mellan enskilda grupper	15
II	FLER-VÄGS VARIANSANALYS	
	1. Introduktion	17
	2. Två-vägs variansanalys	17
	3. Tre-vägs variansanalys	24
III	KORRELATION OCH REGRESSION	
	1. Introduktion	28
	2. Korrelation	28
	3. Regression	31
IV	KOVARIANSANALYS	
	1. Introduktion	37
	2. Skillnader mellan varians- och kovariansanalys	37
	3. Grafisk framställning av kovariansanalys	38
	4. Signifikansprövning vid kovariansanalys	40
	5. Villkor för kovariansanalys	41
	TABELLER	44
	LITTERATURREFERENSER	50
	ÖVNINGSUPPGIFTER	51
	FACIT	62

EN-VÄGS VARIANSANALYS

I INTRODUKTION

En statistisk metodik av generell användbarhet inom många vetenskaper är variansanalys. Namnet på metoden ger en antydning om vad den innebär, nämligen en analys av den observerade variationen i erhållna undersökningsdata. Namnet kan dock vara missledande så tillvida som man egentligen inte är intresserad av att undersöka skillnader mellan olika spridningsmått (varianser), utan man använder sig av olika variansmått för att få veta om vissa centralmått (aritmetiska medeltal) skiljer sig signifikant åt.

I det enklaste fallet innebär variansanalysen att man undersöker om två eller flera stickprovsmedeltal varierar (skiljer sig åt) så mycket, att stickproven med en viss sannolikhet kan anses komma från populationer med skilda medeltal. Denna typ av variansanalys kallas för en-vägs variansanalys. Till skillnad från konventionella t-testningar kan en-vägs variansanalys användas, om man samtidigt vill studera skillnaderna mellan fler än två stickprovsmedeltal.

Vid en en-vägs variansanalys förekommer en oberoende variabel, vilket innebär att man studerar utfallet i en beroende variabel för grupper som har olika värden eller positioner i en oberoende variabel. Man kan t.ex. studera viktökningen bland svin som erhållit olika typer av foder eller inlärningsresultaten hos elevgrupper som erhållit undervisning av varierande längd.

En annan typ av variansanalys är två-vägs variansanalys, vilken gör det möjligt att samtidigt studera två oberoende variabler, t.ex. hur olika slags jordmån och olika typer av gödsel påverkar avkastningen av ett visst slags spannmål. Om man samtidigt vill undersöka tre oberoende variabler, kan man utföra en tre-vägs variansanalys osv. Variansanalyser med fler än tre oberoende variabler inblandade är dock synnerligen sällsynta inom beteendevetenskaperna.

Samtliga typer av variansanalys kan användas såväl vid experimentella undersökningar som vid icke-experimentella undersökningar (sambandsundersökningar). I det förra fallet benämns ofta den oberoende variabeln behandlingsvariabel (treatment variable) och i det senare fallet klassificeringsvariabel (classification variable).

Variansanalysen är en parametrisk metod, vilket innebär att data skall vara uttryckta i intervallskala. Vidare skall fördelningarna vara normala och varianserna lika i de populationer, varifrån stickproven är dragna. Såväl kravet på normalitet som kravet på varianshomogenitet kan man pröva med särskilda testmetoder. Påpekas kan dock att variansanalysen är en ganska robust metod, vilken är relativt okänslig för smärre avvikelser från dessa båda krav.

II EN JÄMFÖRELSE MELLAN EN- OCH TVÅ-VÄGS VARIANSANALYS

De två mest förekommande typerna av variansanalys är en-vägs och två-vägs. Som ovan nämndes skiljer de sig åt med avseende på antalet oberoende variabler som samtidigt studeras. En annan skillnad är att man vid en-vägs variansanalys studerar skillnader mellan gruppmedeltal, medan man vid två-vägs variansanalys studerar: a) skillnader mellan radmedeltal, b) skillnader mellan kolumnmedeltal samt c) interaktionen (samspelet) mellan rad- och kolumnmedeltal.

För att närmare lära känna de båda typerna av variansanalys bör Du läsa igenom nedanstående exempel samt försöka besvara de åtföljande frågorna.

Exempel 1:

För att undersöka vilken stav som är bäst att använda vid stavhoppstävlingar görs en experimentell undersökning. Man väljer ut 30 idrottsmän som samtliga har presterat hopp mellan 380 cm och 400 cm. Idrottsmännen indelas slumpmässigt i 3 grupper. Grupp A tilldelas en brun stav, grupp B en blå stav och grupp C en röd stav. Härfter får grupperna träna 10 timmar per vecka under 3

månader. Nedan återfinns gruppernas medeltal efter träningsperioden:

A	B	C
430 cm	460 cm	490 cm

Exempel 2:

För att undersöka om det finns något samband mellan föräldrarnas inkomst och barnens matematikbetyg i årskurs 6 - dvs. om det finns några skillnader i betyg mellan elever från olika inkomstgrupper - görs följande undersökning. Man konstruerar tre inkomstklasser: HÖG (över 200.000 kr/år), MEDEL (100.000-200.000 kr/år) och LÅG (under 100.000 kr/år). Sedan väljer man ut 100 barn från varje inkomstklass och tar reda på barnens matematikbetyg. Gruppernas genomsnittliga betyg framgår nedan:

HÖG	MEDEL	LÅG
4.2	3.5	2.8

Frågor:

Vilken statistisk metodik kan man använda i exempel 1 respektive 2?

Vilka kausala tolkningar är möjliga i exempel 1 respektive 2?

Exempel 3:

Vi gör ett tillägg till exempel 1, såtillvida att vi väljer ut ytterligare 30 "4-metersmän", vilka slumpas på grupp A, B och C, men dessa 30 får träna i 6 månader i stället för 3. I tabellen nedan finns såväl de tidigare redovisade medeltalen som "nykomlingarnas" medeltal.

Tränings- period	Grupp			Radmedeltal
	A	B	C	
3 mån	430	460	490	
6 mån	500	500	500	
Kolumn- medeltal				

Frågor:

Vad blir radmedeltalen?

Vad blir kolumnmedeltalen?

Finns det någon interaktionseffekt?


Hur skall vi bygga ut undersökningen i exempel 2, för att kunna använda två-vägs variansanalys?

III INOM- OCH MELLANGRUPPSVARIANSMÅTT

Variansanalysen bygger på det förhållandet att avvikelsen mellan ett individuellt mätvärde och totalmedelvärdet kan uppdelas i olika komponenter. Vid en en-vägs variansanalys kan denna avvikelse uppdelas i två komponenter: Avvikelsen mellan det individuella mätvärdet och den egna gruppens medelvärde samt avvikelsen mellan gruppens medelvärde och totalmedelvärdet.

Genom att summera, kvadrera och dividera dessa båda typer av avvikelser erhåller man så småningom ett inom- och ett mellangrups- variansmått, vilka spelar en central roll inom variansanalysen. I följande exempel skall vi försöka visa hur man kommer fram till dessa variansmått.

I en undersökning ingick tre grupper med två individer i varje grupp. Samtliga individuella mätvärden liksom gruppmedeltal och totalmedeltal återges i figuren nedan. Varje individuellt värde har en tvåsiffrig index, där första siffran anger individnummer och andra siffran gruppnummer. Gruppmedeltalen har ett ensiffrigt index och totalmedeltalet är indexfritt. X_{11} anger sålunda mätvärdet för individ nummer ett i den första gruppen och \bar{X}_1 medeltalet för denna grupp. Mera generellt anger X_{ij} mätvärdet för den i :te individen i den j :te gruppen och \bar{X}_j medeltalet för grupp j .



Nedan följer två identiteter. Sätt in de numeriska värdena i dessa samt markera respektive avvikelser i figuren.

$$1) X_{11} \text{ avvikelse från } \bar{X} = (X_{11} - \bar{X}) = (X_{11} - \bar{X}_1) + (\bar{X}_1 - \bar{X})$$

$$2) X_{21} \text{ avvikelse från } \bar{X} = (X_{21} - \bar{X}) = (X_{21} - \bar{X}_1) + (\bar{X}_1 - \bar{X})$$

Mera generellt kan identiteten skrivas:

$$X_{ij} \text{ avvikelse från } \bar{X} = (X_{ij} - \bar{X}) = (X_{ij} - \bar{X}_j) + (\bar{X}_j - \bar{X})$$

Om båda sidor i denna identitet kvadreras och vi summerar över samtliga individer i grupp j erhålles:

$$\sum_{i=1}^{n_j} (X_{ij} - \bar{X})^2 = \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_j)^2 + \sum_{j=1}^{n_j} (\bar{X}_j - \bar{X})^2 + 2(\bar{X}_j - \bar{X}) \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_j)$$

Den andra termen till höger kan skrivas $n_j(\bar{X}_j - \bar{X})^2$, eftersom man summerar en konstant över n_j individer.

Den tredje termen till höger kan du stryka ett streck över, ty den blir alltid lika med noll. Förklaringen härtill är att denna term bl a innehåller summan av individernas avvikelser från det egna gruppmedeltalet, vilken summa givetvis är noll. Om vi ej hade kvadrerat uttrycket så hade den första termen rönt samma öde.

Exemplifiering för grupp 1:

A. Kvadrering

$$(-13)^2 = (-3)^2 + (-10)^2 + 2(-3)(-10)$$

$$(-7)^2 = (+3)^2 + (-10)^2 + 2(+3)(-10)$$

B. Summering

$$\begin{aligned} [(-13)^2 + (-7)^2] &= [(-3)^2 + (+3)^2] + [(-10)^2 + (-10)^2] + \\ &\quad + 2(-10) [(-3) + (+3)] \end{aligned}$$

$$\begin{aligned} [169 + 49] &= [9 + 9] + [100 + 100] + 2(-10) \cdot 0 \\ 218 &= 18 + 200 + 0 \end{aligned}$$

Om vi slutligen summerar över samtliga (k) grupper erhålles följande uttryck:

$$\sum_{j=1}^k \sum_{i=1}^{n_j} (X_{ij} - \bar{X})^2 = \sum_{j=1}^k \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_j)^2 + \sum_{j=1}^k n_j (\bar{X}_j - \bar{X})^2$$

Denna identitet lyder:

Summan av de kvadrerade avvikelser mellan individvärdena och totalmedeltalet =
 en INOMGRUPPSKVADRATSUMMA, dvs. summan av individernas kvadrerade avvikelser från det egna gruppmedeltalet
 + en MELLANGRUPPSKVADRATSUMMA, dvs. summan av de kvadrerade avvikelserna mellan grupp- och totalmedeltal, där varje sådan avvikelse multiplicerats med antalet individer i respektive grupp.

Dessa båda summor är oberoende, dvs. att det finns inget förhållande eller samband mellan de båda summorna - den ena summan kan vara stor och den andra liten, båda kan vara stora, båda kan vara små etc.

Till varje kvadratsumma hör ett bestämt antal frihetsgrader (degrees of freedom - df -)

Om det totala antalet individer som ingår i en analys betecknas med N och antalet individer i en grupp med n , finns det totalt $N-1$ frihetsgrader. Hur kan man förklara det? Möjligen på följande sätt: En variansanalys bygger på avvikelser från medeltal och summan av samtliga individuella avvikelser från totalmedeltal är 0. I och med att man har fixerat totalmedeltalet kan man fritt välja alla individuella värden utom det sista, dvs. man har förlorat en frihetsgrad i och med att totalmedeltalet är bestämt.

Till inomgruppskvadratsumman hör $N-k$ frihetsgrader. Inom varje grupp finns det $n-1$ frihetsgrader. En frihetsgrad förloras i och med att vi bestämt gruppmedeltalet. Sammanlagt inom k grupper finns det $(n_1-1) + (n_2-1) + \dots + (n_k-1) = N-k$ frihetsgrader.

Till mellangruppskvadratsumman hör $k-1$ frihetsgrader. Då totalmedelvärdet bestämts kan jag fritt placera ut samtliga gruppmedeltal utom det sista.

Frihetsgraderna är additiva.

Totalt	=	Inom	+	Mellan
$(N-1)$		$(N-k)$		$(k-1)$

I vårt exempel var $N=6$ och $k=3$. Ange antalet frihetsgrader som hör till de olika kvadratsummorna!

Om inom- och mellangruppskvadratsummorna divideras med sitt frihetsgradsantal erhålls de s.k. variansmått, även kallade medelkvadrater (mean squares).

$$\frac{\text{Mellangruppskvadratsumman}}{k-1} = S_b^2 \hat{=} \text{mellangruppsvariansmått}$$

$$\frac{\text{Inomgruppskvadratsumman}}{N-k} = S_w^2 = \text{inomgruppsvariansmått}$$

Variansmått är - i motsats till kvadratsummor och frihetsgrader - ej additiva. Man kan således ej få fram något totalt variansmått, genom att addera mellan- och inomgruppsvariansmått. Däremot erhåller man en F-kvot genom att dividera mellangruppsvariansmättet med inomgruppsvariansmättet.

$$\frac{S_b^2}{S_w^2} = \text{F-kvot}$$

Genom att sedan gå in i en F-tabell kan vi få reda på om det finns signifikanta skillnader mellan gruppmedeltalen, dvs. om samtliga stickprov med en viss sannolikhet kan anses dragna från samma population eller ej. Om stickproven kommer från samma population blir F ungefär lika med 1, i annat fall blir F betydligt större än 1.

Innan F-kvoten behandlas utförligare, skall vi närmare granska de båda krumelurerna S_b^2 och S_w^2 .

Med hjälp av tidigare givna ekvationer torde den i statistik något bevandrade läsaren kunna uttolka vad symbolerna innebär, nämligen:

S_w^2 = den genomsnittliga variansen inom grupperna, dvs. den genomsnittliga spridningen inom grupperna i kvadrat.

S_b^2 = variansen (den kvadrerade spridningen) i medeltalsfördelningen multiplicerad med gruppstorleken.

Den misstroagna eller i statistik något mindre hemmastadde läsaren hänvisas till bevisföringen i Ferguson (s. 287-288).

Varför blir då F-kvoten ett eller ungefär lika med ett, om stickproven kommer från samma population?

Om samtliga stickprov kommer från samma population bör spridningarna inom stickproven vara ungefär lika och de smärre differenser som kan finnas har åstadkommit av slumpen (samplingsfel).

$$S_1 \approx S_2 \approx S_3 \approx \dots \approx S_k$$

Den genomsnittliga spridningen inom grupperna (medeltalet av samtliga spridningar) S_w ger oss en god skattning av spridningen i populationen (σ). Likaså ger oss S_w^2 en god skattning av variansen i populationen (σ^2).

Vidare - om stickproven är dragna från samma population - får vi spridningen i medeltalsfördelningen (medelfelet) enligt följande formel:

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

där σ är spridningen i populationen och n är lika med gruppstorleken

Härav följer att:

$$\sigma = \sqrt{n} \sigma_{\bar{X}}$$

Om båda sidor kvadreras erhålles:

$$\sigma^2 = n \sigma_{\bar{X}}^2$$

Men vi vet att det högra ledet i ekvationen (gruppstorleken multiplicerad med variansen i medeltalsfördelningen) är lika med S_b^2 .

Härav följer att $\sigma^2 = S_b^2$


Tidigare har vi också visat att $\sigma^2 = S_w^2$

Dvs. ett om stickproven kommer från samma population blir $S_w^2 = S_b^2$, ty båda är lika med variansen i populationen (σ^2) - och

$$F\text{-kvoten} = \frac{S_b^2}{S_w^2} = \frac{\sigma^2}{\sigma^2} = 1$$

För att belysa det kanske något svårsmälta resonemanget ovan skall vi ge följande exempel:

10 stickprov om 10 individer i varje dras från samma population. Varje individ får genomgå ett prov i elementär matematik. Här- efter beräknas medeltal och spridning inom varje grupp. Såväl medeltal som spridning varierar något från stickprov till stick- prov. Den genomsnittliga spridningen inom grupperna uppgår till 12. Spridningen i medeltalsfördelningen uppgår till 3.8.



$$S_w^2 = 12^2 = 144; \text{ (den genomsnittliga spridningen inom grupperna i kvadrat)}$$


$$S_b^2 = 3.8^2 \cdot 10 = 14.4 \cdot 10 = 144$$

$$F = \frac{S_b^2}{S_w^2} = \frac{144}{144} = 1$$

F-kvoten är ej signifikant, vilket är ganska självklart eftersom stickproven kommer från samma population.

Vi skall så ge ett exempel där stickproven kommer från olika populationer:

Ett prov i trafikknus bjuds till 11 olika grupper av förare. I varje grupp ingår 10 personer. Medeltal och spridning på provet beräknas inom varje grupp. Likaså den genomsnittliga spridningen inom grupperna samt spridningen i medeltalsfördelningen.



$$S_w^2 = 4^2 = 16;$$

$$S_b^2 = 10 \cdot 6^2 = 360$$

$$F = \frac{S_b^2}{S_w^2} = \frac{360}{16} = 22.5$$

Är detta värde signifikant? Gå till F-tabellen. Denna läses på följande sätt:

$$\frac{S_b^2}{S_w^2} \quad \Rightarrow \quad \text{d.f.} = k-1 = 11-1 = 10$$

$$\Downarrow$$

$$\text{d.f.} = N-k = 110-11 = 99$$

Något F-värde finns ej för df: 10; 99, varför vi går till df: 10; 100, där vi finner

1.92
2.51

Detta innebär att vi i vårt fall måste ha ett F-värde på 1.92 för att det skall finnas signifikanta skillnader mellan grupperna på 5 %-nivån. Vidare måste vi ha ett F-värde på minst 2.51 för att de skall finnas signifikanta skillnader på 1 %-nivån. Vårt F-värde på 22.5 upplyser om att det finns starka signifikanta skillnader mellan grupperna.

Vi avslutar detta avsnitt med följande påpekanden:

- 1) Om F är lika med eller ungefär lika med 1 innebär det att $S_b^2 \approx S_w^2$, vilket innebär att skillnaderna inom grupperna är ungefär lika stora som skillnaderna mellan grupperna. I den undersökta variabeln är sålunda gruppmedlemmarna ej mer lika inbördes, än vad de är lika övriga grupperns medlemmar och samtliga grupper torde komma från samma population.
- 2) Om F är betydligt större än 1 innebär det att $S_b^2 > S_w^2$, vilket beror på att skillnaderna inom grupperna är mindre än skillnaderna mellan grupperna. Gruppmedlemmarna är i den aktuella variabeln mer lika varandra än vad de är lika övriga grupperns medlemmar, vilket tolkas som att grupperna tillhör olika populationer.

- 3) F-fördelningens form varierar beroende på antalet frihetsgrader i täljare och nämnare. För en beskrivning av F-fördelningarnas utseende hänvisas till Walker och Lew (1953, s. 207-209).
- 4) Ju större grupperna är och ju fler grupper som ingår i undersökningen, ju lägre F-kvot krävs för signifikans, vilket framgår av F-tabellen.
- 5) Oftast använder man sig av en annan och enklare metodik vid räkningsarbetet än de "åskådlighetsmetodiker" som vi hittills tillämpat. De beräkningsformler som behövs återfinns i följande avsnitt.
- 6) Rent allmänt torde man kunna påstå: *Att mekaniskt utföra en variansanalys är relativt enkelt; att förstå vad en variansanalys verkligen innebär är betydligt svårare.*

IV BERÄKNINGSFORMLER VID EN-VÄGS VARIANSANALYS

Själva räkningsarbetet vid en variansanalys underlättas avsevärt om man använder följande formler:

Inomgruppskvadratsumman:

$$\sum_{j=1}^k \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_j)^2 = \sum_{j=1}^k \sum_{i=1}^{n_j} X_{ij}^2 - \sum_{j=1}^k \left(\frac{T_j^2}{n_j} \right)$$

Mellangruppskvadratsumman:

$$\sum_{j=1}^k n_j (\bar{X}_j - \bar{X})^2 = \sum_{j=1}^k \left(\frac{T_j^2}{n_j} \right) - \frac{T^2}{N}$$

Totalkvadratsumman:

$$\sum_{j=1}^k \sum_{i=1}^{n_j} (X_{ij} - \bar{X})^2 = \sum_{j=1}^k \sum_{i=1}^{n_j} X_{ij}^2 - \frac{T^2}{N}$$

Anmärkningar:

1. I formlerna står T_j för samtliga mätvärden i den j :te gruppen och T för summan av samtliga mätvärden.

2. Totalkvadratsumman behöver man egentligen inte räkna ut, eftersom den inte behövs i det fortsatta beräkningsarbetet. Om man räknar ut den får man emellertid en kontroll av att inom- och mellangruppskvadratsummorna är rätt räknade. Hur gör man denna kontroll?
3. Om individantalet är lika i samtliga grupper förenklas formlerna enligt följande:

Inomgruppskvadratsumman:

$$\sum_{j=1}^k \sum_{i=1}^n X_{ij}^2 - \frac{\sum_{j=1}^k T_j^2}{n}$$

Mellangruppskvadratsumman:

$$\frac{\sum_{j=1}^k T_j^2}{n} - \frac{T^2}{N}$$

I följande exempel kommer vi att tillämpa beräkningsformlerna:

För att undersöka effekten av tre olika bantningskurer, ANTIFETT -, BANTALÄTT - respektive CURACAOMETODEN, väljer man ut 15 försökspersoner. Dessa fördelas slumpmässigt på de tre metoderna. Efter en månads bantning registrerar man viktminskningen, vilken återges i nedanstående tabell. Med utgångspunkt från denna skall vi se om det finns några skillnader mellan metoderna, dvs. vi skall testa nollhypotesen.

$$H_0: \mu_1 = \mu_2 = \mu_3$$

Grupp	I	II	III
	1	2	3
	2	3	4
	3	4	5
	4	5	6
	5	6	7

Grupp	I	II	III	
n	5	5	5	N = 15
T _j	15	20	25	T = 60
\bar{X}_j	3	4	5	$\frac{T^2}{N} = 240$
$\sum_{i=1}^n X_{ij}^2$	55	90	135	$\sum_{j=1}^k \sum_{i=1}^n X_{ij}^2 = 280$

Kvadratsummor:

$$\text{Mellan} = \frac{\sum_{j=1}^k T_j^2}{n} - \frac{T^2}{N} = 250 - 240 = 10$$

$$\text{Inom} = \sum_{j=1}^k \sum_{i=1}^n X_{ij}^2 - \frac{\sum_{j=1}^k T_j^2}{n} = 280 - 250 = 30$$

$$\text{Totalt:} \quad \sum_{j=1}^k \sum_{i=1}^n X_{ij}^2 - \frac{T^2}{N} = 280 - 240 = 40$$

Resultaten sammanfattas i följande tabell:

Variationskälla	Kvadratsumma	df	Variansmått	F
Mellan	10	2	5	2
Inom	<u>30</u>	<u>12</u>	2.5	
Totalt	40	14		

Kritiskt värde för 5 %-nivån (df = 2 och 12) = 3.88.

Hur vill Du tolka utfallet av analysen?

V SKILLNADER MELLAN ENSKILDA GRUPPER

Om man får en signifikant F-kvot, ger den endast upplysning om att det finns signifikanta skillnader mellan vissa grupper. Däremot får man ej veta, mellan vilka grupper som skillnaderna är signifikanta. När man erhållit en signifikant F-kvot, och det i analysen ingår fler än två grupper, får man därför gå vidare och signifikantstesta skillnaderna mellan de olika gruppmedeltalen. Härvid används följande formel:

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_w^2}{n_1} + \frac{S_w^2}{n_2}}}$$

\bar{X}_1 = = medeltalet för grupp 1

\bar{X}_2 = = medeltalet för grupp 2

n_1 = = antalet individer i grupp 1

n_2 = = antalet individer i grupp 2

S_w^2 = inomgruppsvariansmättet

Om vi återvänder till exemplet med provet i trafikkunskap (sid 10) och signifikantstestar skillnaden mellan grupp 2 och 1 får vi följande värde:

$$t = \frac{26-20}{\sqrt{\frac{4^2}{10} + \frac{4^2}{10}}} = \frac{6}{\sqrt{3.2}} = 3.35$$

När en t-testning följer på en F-testning används det frihetsgrädsantal som gäller för inomgruppsvariansmättet (som hela tiden återfinns i nämnaren). I detta fall blir således antalet frihetsgrader

99. De kritiska värdena för t kan utläsas ur tabellen på sidan 45. På 1%-nivå uppgår det kritiska värdet till 2.63, vilket innebär att skillnaden mellan grupp 2 och 1 är signifikant.

I det nämnda exemplet ingick elva grupper. Låt oss kalla den grupp som har det högsta medeltalet för A, gruppen med det näst högsta för B etc. När man skall t -testa skillnaderna mellan medeltalen, börjar man med skillnaden mellan de båda högsta, dvs mellan A och B. Om denna differens är signifikant innebär det att A:s medeltal är signifikant högre än alla de andra gruppernas. Sedan går man vidare och testar differensen mellan B och C, C och D osv. Testningarna går snabbt att genomföra ty som framgår av formeln förblir nämnaren hela tiden densamma.

Resultaten av t -testningarna redovisas genom att man ordnar gruppmedeltalen i fallande storleksordning samt stryker ett streck under de medeltal som inte är signifikant åtskilda, t ex:

A B C D E F G H I J K

Genom denna uppställning får man en snabb överblick av variansanalysens utfall - A:s medeltal är signifikant högre än B:s, som i sin tur är signifikant högre än C:s, D:s och E:s. Mellan dessa tre grupper finns ingen signifikans, men alla är signifikant större än

Kapitel 2

FLER-VÄGS VARIANSANALYSI INTRODUKTION

En undersökning kan ges en sådan uppläggning att man samtidigt kan studera hur två eller flera oberoende variabler - också kallade experimentella variabler eller faktorer - inverkar på en beroende variabel. Denna typ av designer kallas vanligen för faktoriella designer.

Om man har två oberoende variabler, vilka båda endast kan anta två värden (nivåer eller levels), har man en 2×2 design. Om båda variablerna kan anta tre värden får man en 3×3 design. I bägge fallen rör det sig om två-vägs variansanalys. Varför?

Använder man sig av tre oberoende variabler, som vardera kan anta två värden erhåller man en $2 \times 2 \times 2$ design. I detta fallet kan man utföra en tre-vägs variansanalys. Försök att ge exempel på en $4 \times 3 \times 2$ design.

II TVA-VÄGS VARIANSANALYS

För att undersöka effekten av två olika bantningskurer - Apelsinmetoden respektive Bananmetoden - vid behandlingsperioder av varierande längd görs en experimentell undersökning. 60 personer i viktlassen 110 till 120 kg fördelas slumpvis på behandling A och B. Inom varje behandlingsgrupp uppdelas individerna sedan i tre undergrupper, vilka erhåller 10, 20 respektive 30 veckors behandling.

I denna undersökning har man alltså en 2×3 design - eller en design bestående av 2 rader och 3 kolumner med 10 individer i varje cell. Designen illustreras i nedanstående tablå, där vi även redovisat indexmarkeringarna vid en två-vägs variansanalys. Första indexet betecknar radtillhörigheten, andra indexet kolumntillhörigheten och tredje indexet individens nummer inom cellen. En eller flera punkter symboliserar någon typ av medeltal.

		Kolumn		
		1	2	3
Rad	1	X_{111} \vdots	X_{121} \vdots	X_{131} \vdots
	2	X_{211} \vdots	X_{221} \vdots	X_{231} \vdots

Försök att placera in följande krumelurer i tablan:

$$\begin{array}{ll}
 X_{237} & \bar{X}_{.2.} \\
 \bar{X}_{12.} & \bar{X}_{...} \\
 \bar{X}_{1..} & X_{rci}
 \end{array}$$

Liksom vid en en-vägs variansanalys kan en viss individs avvikel-
se från totalmedeltalet uppdelas i olika additiva delar:

$$\begin{aligned}
 (X_{rci} - \bar{X}_{...}) &= (\bar{X}_{r..} - \bar{X}_{...}) \\
 &+ (\bar{X}_{.c.} - \bar{X}_{...}) \\
 &+ (\bar{X}_{rc.} - \bar{X}_{r..} - \bar{X}_{.c.} + \bar{X}_{...}) \\
 &+ (X_{rci} - \bar{X}_{rc.})
 \end{aligned}$$

Detta uttryck innebär att individens avvikelse från totalmedel-
talet uppdelas i:

- 1)
- 2)
- 3)
- 4)

Vad blir de fyra komponenterna om följande värden gäller:

$$X_{rci} = 55, \bar{X}_{r..} = 35, \bar{X}_{.c.} = 35, \bar{X}_{rc.} = 50, \bar{X}_{...} = 25$$

Om samtliga avvikelser kvadreras och summeras över samtliga rader, kolumner och celler erhålles fem kvadratsummor: total-, rad-, kolumn-, interaktions- och inom-cells kvadratsumma. Om de fyra sista kvadratsummorna divideras med sina respektive frihetsgradsantal erhålles fyra variansmått (se tabellen nedan). Fortfarande är kvadratsummor och frihetsgrader additiva - så ej variansmått.

Variationskällor, kvadratsummor, frihetsgrader och variansmått vid en två-vägs variansanalys med n individer i varje cell.

Variationskälla	Kvadratsumma	df	Variansmått
Rader	$nC \sum_{r=1}^R (\bar{Y}_{r..} - \bar{X}_{...})^2$	$R-1$	S_r^2
Kolumner	$nR \sum_{c=1}^C (\bar{X}_{.c.} - \bar{X}_{...})^2$	$C-1$	S_c^2
Interaktion	$n \sum_{r=1}^R \sum_{c=1}^C (\bar{X}_{rc.} - \bar{X}_{r..} - \bar{X}_{.c.} + \bar{X}_{...})^2$	$(R-1)(C-1)$	S_i^2
Inom celler	$\sum_{r=1}^R \sum_{c=1}^C \sum_{i=1}^n (X_{rci} - \bar{X}_{rc.})^2$	$RC(n-1)$	S_w^2
Totalt	$\sum_{r=1}^R \sum_{c=1}^C \sum_{i=1}^n (X_{rci} - \bar{X}_{...})^2$	$nRC-1$	

Nedan redovisas två hypotetiska utfall av vår bantningsundersökning. I utfall 1 saknas och i utfall 2 finns en interaktionseffekt. Hur kan man se detta?


	Utfall 1				Utfall 2			
	10 v	20 v	30 v		10 v	20 v	30 v	
A-metoden	10	20	30	20	10	15	17	14
B-metoden	20	30	40	30	10	20	30	20
	15	25	35	25	10	17.5	23.5	17

Om det ej finns någon interaktionseffekt gäller följande identitet för samtliga cellmedeltal:

$$\bar{X}_{rc.} = \bar{X}_{r..} + \bar{X}_{.c.} - \bar{X}_{...}$$

Gör en prövning av de givna resultaten.

Vi kan också avslöja interaktionseffekten grafiskt, genom att plocka in cellmedeltalen i nedanstående diagram:



En två-vägs variansanalys leder fram till en F-testning av:

a) radeffekten, b) kolumneffekten och c) interaktionseffekten.

Innan man gör testningarna måste man besluta sig för vilken modell som gäller, ty modellen bestämmer valet av felterm (= nämnaren vid F-testningen).

Tre modeller finnes:

Modell I (FIXED MODEL)

Modell II (RANDOM MODEL)

Modell III (MIXED MODEL)

Inom beteendevetenskaplig forskning arbetar man oftast efter modell I, dvs. värdena på den oberoende variabeln har valts därför att de är av speciellt intresse och anses ej slumpvis valda ur en stor "värdepopulation". Är värdena i båda variablerna slumpvis valda - vilket torde vara synnerligen sällsynt - får man tillämpa modell II. Är värdena slumpvis valda enbart i den ena variabeln väljs modell III.

När man arbetar utifrån modell I används inom-cellsvariationsmättet som felterm vid samtliga tre F-testningar. Valet av felterm vid de båda övriga modellerna redovisas av Ferguson (1966, s. 310). För en utförligare diskussion i denna fråga hänvisas till Edwards (1960).

Här redovisas ytterligare ett tänkbart utfall av vårt bantningsexperiment. Det blir din uppgift att komplettera tabellen med frihetsgradsantal, variansmått och F-kvoter - samt att redogöra för de funna F-värdenas innebörd.

Variationskälla	Kvadratsumma	df	Variansmått	F
Rader	750			
Kolumner	1100			
Interaktion	300			
Inom celler	5400			
Totalt	7550			

Även vid en två-vägs variansanalys förekommer särskilda beräkningsformler. Vi skall redovisa dem i samband med följande exempel:

I en undersökning studerade man hur två olika undervisningsmetoder i engelska (C_1 och C_2), vilka pågått under tio respektive 20 veckor (R_1 respektive R_2), inverkat på kunskapsbehållningen. Denna mättes med ett prov, där eleverna kunde erhålla maximalt 20 poäng. I tabellen återfinns samtliga elevers resultat på provet. Utifrån

dessa data skall vi signifikanstesta rad-, kolumn- och interaktionseffekten (Modell I gäller).

	C ₁	C ₂	
R ₁	3	8	
	4 T ₁₁ = 25	9 T ₁₂ = 50	T _{1.} = 75
	5	10	
	6 $\bar{X}_{11.} = 5$	11 $\bar{X}_{12.} = 10$	$\bar{X}_{1..} = 7.5$
	7	12	
R ₂	3	13	
	4 T ₂₁ = 25	14 T ₂₂ = 75	T _{2.} = 100
	5	15	
	6 $\bar{X}_{21.} = 5$	16 $\bar{X}_{22.} = 15$	$\bar{X}_{2..} = 10$
	7	17	
	T _{.1} = 50	T _{.2} = 125	T = 175
	$\bar{X}_{.1.} = 5$	$\bar{X}_{.2.} = 12.5$	$\bar{X}_{...} = 8.75$

Radsummorna i kvadrat:

$$\sum_{r=1}^R T_{r.}^2 = 75^2 + 100^2 = 15\,625$$

Kolumnsummorna i kvadrat:

$$\sum_{c=1}^C T_{.c}^2 = 50^2 + 125^2 = 18\,125$$

Cellsummorna i kvadrat:

$$\sum_{r=1}^R \sum_{c=1}^C T_{rc}^2 = 25^2 + 50^2 + 25^2 + 75^2 = 9\,375$$

Summan av de individuella värdena i kvadrat:

$$\sum_{r=1}^R \sum_{c=1}^C \sum_{i=1}^n X_{rci}^2 = 3^2 + 4^2 + 5^2 + \dots + 16^2 + 17^2 = 1\,915$$

I och med att vi har räknat ut dessa fyra summor har vi fått fram det "råmaterial" som behövs för att beräkna rad-, kolumn-, interaktions-, inom-cells- samt totalkvadratsumman. Dessa erhålls med hjälp av följande formler:

Radkvadratsumman.

$$\frac{1}{nC} \sum_{r=1}^R T_{r.}^2 - \frac{T^2}{N} = \frac{15625}{5 \cdot 2} - \frac{175^2}{20} = 31.2$$

Kolumnkvadratsumman:

$$\frac{1}{nR} \sum_{c=1}^C T_{.c}^2 - \frac{T^2}{N} = \frac{18125}{5 \cdot 2} - \frac{175^2}{20} = 281.2$$

Interaktionskvadratsumman:

$$\begin{aligned} \frac{1}{n} \sum_{r=1}^R \sum_{c=1}^C T_{rc}^2 - \frac{1}{nC} \sum_{r=1}^R T_{r.}^2 - \frac{1}{nR} \sum_{c=1}^C T_{.c}^2 + \frac{T^2}{N} = \\ = \frac{9375}{5} - \frac{15625}{5 \cdot 2} - \frac{18125}{5 \cdot 2} + \frac{175^2}{20} = 31.3 \end{aligned}$$

Inom-cellskvadratsumman:

$$\sum_{r=1}^R \sum_{c=1}^C \sum_{i=1}^n X_{rci}^2 - \frac{1}{n} \sum_{r=1}^R \sum_{c=1}^C T_{rc}^2 = 1915 - \frac{9375}{5} = 40$$

Totalkvadratsumman:

$$\sum_{r=1}^R \sum_{c=1}^C \sum_{i=1}^n X_{rci}^2 - \frac{T^2}{N} = 1915 - \frac{175^2}{20} = 383.7$$

De fem kvadratsummorna återfinns i nedanstående tabell, där vi även angett frihetsgradsantal och variansmått:

Variationskälla	Kvadratsumma	df	Variansmått
Rader	31.2	1	31.2
Kolumner	281.2	1	281.2
Interaktion	31.3	1	31.3
Inom celler	40	16	2.5
Totalt	383.7	19	

F-värden: $F_r = \frac{31.2}{2.5} = 12.48$

$$F_c = \frac{281.2}{2.5} = 112.48$$

$$F_i = \frac{31.3}{2.5} = 12.52$$

Nu återstår bara en sak, nämligen tolkningen av resultatet. Detta överlämnas med varm hand till läsaren.

III TRE-VÄGS VARIANSANALYS

För att ge läsaren en åtminstone flyktig förnimmelse av vad en tre-vägs variansanalys innebär, skall vi redogöra för en uppiktad studie, där denna metodik tillämpas.

I en undersökning vill man studera hur retentionen av verbalt material påverkas av tre olika faktorer samt om det finns någon interaktion mellan faktorerna. För att mäta den beroende variabeln använder man sig av en lista bestående av 30 flicknamn. De tre oberoende variablerna är:

A) Presentation: 1) Visuellt

2) Auditiv

B) Antal presentationer: 1) En presentation

2) Två presentationer

C) Återgivning: 1) Omedelbar återgivning

2) Återgivning en timma efter presentationen.

Sammanlagt deltar 40 försökspersoner som slumpvis fördelas på 8 lika stora behandlingsgrupper.

Behandling	Presentation	Antal presentationer	Återgivning
A ₁ B ₁ C ₁	Visuell	En	Omedelbar
A ₁ B ₁ C ₂	"	"	Fördröjd
A ₁ B ₂ C ₁	"	Två	Omedelbar
A ₁ B ₂ C ₂	"	"	Fördröjd
A ₂ B ₁ C ₁	Auditiv	En	Omedelbar
A ₂ B ₁ C ₂	"	"	Fördröjd
A ₂ B ₂ C ₁	"	Två	Omedelbar
A ₂ B ₂ C ₂	"	"	Fördröjd

I denna undersökning utgår man från en 2×2×2 design, vilket möjliggör en tre-vägs variansanalys. I tabellen nedan anges de olika variationskällorna samt frihetsgradsantalen.









Variationskälla	df
A: Presentation (Visuell-Auditiv)	(A-1)=1
B: Antal presentationer (En-Två)	(B-1)=1
C: Återgivning (Omedelbar-Fördröjd)	(C-1)=1
A×B: Presentation × Antal	(A-1)(B-1)=1
A×C: Presentation × Återgivning	(A-1)(C-1)=1
B×C: Antal × Återgivning	(B-1)(C-1)=1
A×B×C: Presentation × Antal × Återgivning	(A-1)(B-1)(C-1)=1
Inom cellerna	ABC(n-1)=32
Totalt	nABC(-1)=39

Under förutsättning att värdena på de tre oberoende variablerna är speciellt utvalda (Modell I gäller), används inomcellsvariationsmättet som felterm vid samtliga F-testningar. Sammanlagt sju sådana testningar kan göras, varvid man får information om:

- 1) Skillnaden mellan visuell och auditiv presentation
- 2) " " " en och två presentationer
- 3) " " " omedelbar och fördröjd återgivning

- 4) Interaktionen mellan presentationssätt och antal presentationer
- 5) " " presentationssätt och återgivning
- 6) " " antal presentationer och återgivning
- 7) " " presentationssätt, antal och återgivning

I undersökningen erhåller de åtta behandlingsgrupperna följande medeltal:

A_1 visuell				A_2 auditiv			
B_1 en		B_2 två		B_1 en		B_2 två	
C_1 omed.	C_2 förd.	C_1 omed.	C_2 förd.	C_1 omed.	C_2 förd.	C_1 omed.	C_2 förd.
							
14	12	24	18	12	10	16	14

Ange de genomsnittliga skillnaderna mellan:

A_1 och A_2

B_1 och B_2

C_1 och C_2

Anser Du skillnaderna realistiska?

Anser Du skillnaderna signifikanta?

Finns det några interaktionseffekter?


Den sista frågan kan belysas med hjälp av några diagram.

Interaktion mellan:


A och B

A och C

B och C



Interaktion mellan A, B och C:



Kapitel 3

KORRELATION OCH REGRESSIONI INTRODUKTION

Innan vi tar steget över från variansanalys till kovariansanalysmetodiken, skall vi uppehålla oss något vid korrelationer och regressionser. Skälet härtill är att kovariansanalysmetoden bygger såväl på variansanalys - som på regressionsmetodik. Vi förutsätter emellertid att flertalet läsare är relativt förtrogna med både korrelations- och regressionskoefficienter, varför genomgången blir relativt kortfattad. För den som vill ha en utförligare framställning av produktmomentkorrelationen hänvisas till Vejde (1965) medan Ferguson (1966) står till förfogande med en mer uttömmande redogörelse för regressionskoefficienter och regressionslinjer.


II KORRELATION

Om det föreligger en korrelation (ett samband) mellan två variabler innebär det att en förändring i den ena variabeln åtföljs av en systematisk förändring i den andra variabeln.

Det finns t.ex. en korrelation mellan längd och vikt så att ju längre en människa är desto mera väger hon som regel.


I detta fall är korrelationen positiv därför att när den ena variabeln (längd) ökar så ökar också den andra variabeln (vikt).

Detta visar sig i ett koordinatsystem så:



Korrelationen kan också vara negativ, vilket innebär att om man har ett högt värde i den ena variabeln motsvaras detta normalt av ett lågt värde i den andra variabeln. T.ex. sambandet mellan antalet svordomar och graden av religiositet (vi antar att religiositeten är en kontinuerlig variabel).

Detta visar sig i ett koordinatsystem så:
antal svordomar (y-variabel)




Slutligen kan det saknas samband mellan två variabler. Man säger då att vi har en nollkorrelation. Detta innebär att en förändring i den ena variabeln inte åtföljs av en systematisk förändring i den andra.

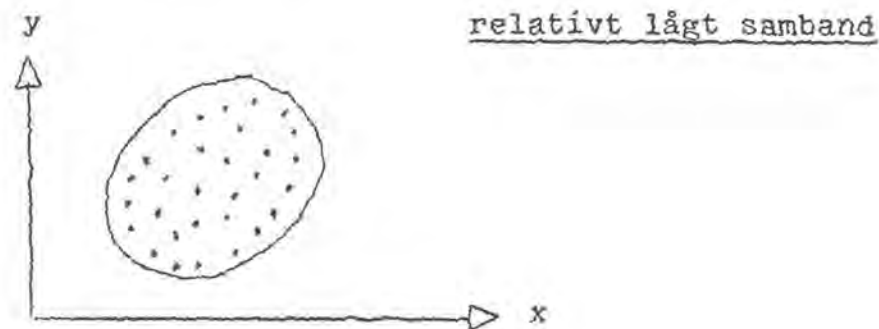
Exempel på nollkorrelation: skonummer och intelligens bland vuxna människor.

Såväl när det gäller positiv som negativt samband kan graden av samband variera från mycket högt till mycket lågt.

Har vi ett högt samband mellan två variabler innebär det att en ökning i den ena variabeln medför en nästan exakt proportionell ökning i den andra variabeln varigenom alla observationer faller inom elipsen i nedanstående figur.



Ju högre sambandet är desto mera långsmal blir elipsen och omvänt desto lägre samband desto mera cirkelformad blir elipsen.



Graden av samband uttrycks med hjälp av en korrelationskoefficient som kan variera från -1 via 0 över till +1.

Om båda variablerna är uttryckta i intervallskala, om fördelningarna är lika i de båda variablerna, samt om sambandet är linjärt, kan detta uttryckas med hjälp av en produktmomentkorrelationskoefficient. Denna koefficient symboliseras av tecknet r eller r_{xy} och kan beräknas utifrån följande formel:

$$r_{xy} = \frac{N \sum xy - \sum x \sum y}{\sqrt{N \sum x^2 - (\sum x)^2} \cdot \sqrt{N \sum y^2 - (\sum y)^2}}$$

Exempel:

Elev	prov 1(x)	prov 2(y)	x^2	y^2	$x \cdot y$
1	33	37	1089	1369	1221
2	8	10	64	100	80
3	20	27	400	729	540
4	39	38	1521	1444	1482
5	16	16	256	256	256
6	20	15	400	225	300
7	24	26	576	676	624
8	31	29	961	841	899
9	13	14	169	196	182
10	40	40	1600	1600	1600
	244	252	7036	7436	7184

Beräkning

- 1) Beräkna Σx
- 2) Beräkna Σy
- 3) Beräkna för varje elev x^2 respektive y^2
- 4) Beräkna Σx^2 respektive Σy^2
- 5) Beräkna för varje elev $x \cdot y$
- 6) Beräkna Σxy
- 7) Sätt in de olika värdena i formeln enligt följande:

$$r_{xy} = \frac{10 \cdot 7184 - 244 \cdot 252}{\sqrt{10 \cdot 7036 - 244^2} \cdot \sqrt{10 \cdot 7436 - 252^2}} = 0.95$$

För att undersöka om korrelationen är signifikant använder man sig av en t-testning:

$$t = r_{xy} \sqrt{\frac{N-2}{1-r_{xy}^2}}$$

I vårt exempel erhålles följande t-värde :

$$t = 0.95 \sqrt{\frac{10-2}{1-0.95^2}} = 0.95 \sqrt{\frac{8}{0.10}} = 0.95 \sqrt{80} = 8.46$$

Vad innebär detta t-värde?

III REGRESSION

När man har beräknat en produktmomentkorrelationskoefficient, kan man sedan lätt beräkna regressionskoefficienten (b_{yx}), ty:

$$b_{yx} = \frac{S_y}{S_x} \cdot r_{xy}$$

Som framgår av formeln blir $b_{yx} = r_{xy}$, då spridningarna i x och y är lika.


Regressionskoefficienten kan också beräknas direkt:

$$b_{yx} = \frac{\Sigma xy - (\Sigma x \Sigma y / N)}{\Sigma x^2 - [(\Sigma x)^2 / N]}$$


Varför skall man räkna ut regressionskoefficienten? Man måste ha den för att kunna beräkna en regressionslinje, med vars hjälp man sedan kan skatta en individs förväntade värde i y-variabeln utifrån hans värde i x-variabeln.

En regressionslinje visas i figuren nedan. För att kunna lägga in denna i ett koordinatsystem måste man dels känna till regressionskoefficienten som anger linjens lutning, och dels avståndet mellan origo och den punkt där linjen skär y-axeln (a_{yx})


$$a_{yx} = \frac{\Sigma y - b_{yx} \Sigma x}{N}$$



Regressionslinjen är dragen på så sätt att summan av de (lodräta) kvadrerade avstånden från de enskilda punkterna når ett minimum. Ju högre korrelationen är, ju starkare lutning får linjen och ju mindre blir summan av de kvadrerade avvikelserna. Om korrelationen är +1 ligger samtliga punkter på linjen och den aktuella kvadratsumman är lika med 0. Om spridningen är lika i x- och y-variabeln har regressionslinjen en lutning på 45° .



Man kan också säga att regressionslinjens lutning anger det genomsnittliga tillskottet i y när x ökar. Om korrelationen är $+1$ ökar x och y med samma hastighet. Om korrelationen är mindre än 1 ökar y saktare än x , dvs. linjen har en lutning som är mindre än 45° . Om korrelationen är 0 sker det ingen systematisk ökning i y när x växer, ty linjens lutning är 0° .



Liksom man kan beräkna en spridning (standardavvikelse) kring ett medeltal kan man beräkna en spridning runt regressionslinjen. Denna betecknas $S_{y.x}$ och fås genom:

$$S_{y.x} = S_y \sqrt{1 - r_{xy}^2}$$

Om spridningen i både x - och y -variabeln är 10 , vilka blir då svaren på följande frågor?

- Vad blir $S_{y.x}$ när $r = 1$?
- Vad blir $S_{y.x}$ när $r = 0$?
- Vad blir $S_{y.x}$ när $r = 0.80$?

Vilket förhållande råder mellan spridningen runt regressionslinjen och korrelationens styrka?

I och för sig behöver man inte avläsa en individs förväntade värde (Y') utifrån en regressionslinje i ett koordinatsystem, utan man kan också erhålla det direkt genom följande formel:

$$Y' = \bar{Y} + b_{yx}(X - \bar{X})$$

Om medeltalet i y (\bar{Y}) = 50, medeltalet i x (\bar{X}) = 50, regressionskoefficienten = 0.80 samt individens x -värde (X) = 60 erhålles följande förväntade y -värde.

$$Y' = 50 + 0.80(60 - 50) = 58$$

Spridningen kring detta förväntade värde blir:


$$S_{y \cdot x} = S_y \sqrt{1 - r_{xy}^2} = 10 \sqrt{1 - 0.80^2} = 6$$

Vilken nytta har vi av dessa upplysningar?

Om en individ har 60 poäng i x -variabeln är hans förväntade värde i y -variabeln 58 poäng. Eftersom korrelationen ej är perfekt finns det dock en viss osäkerhet i vår utsaga. Med 95 % sannolikhet ligger dock hans sanna y -värde inom intervallet:

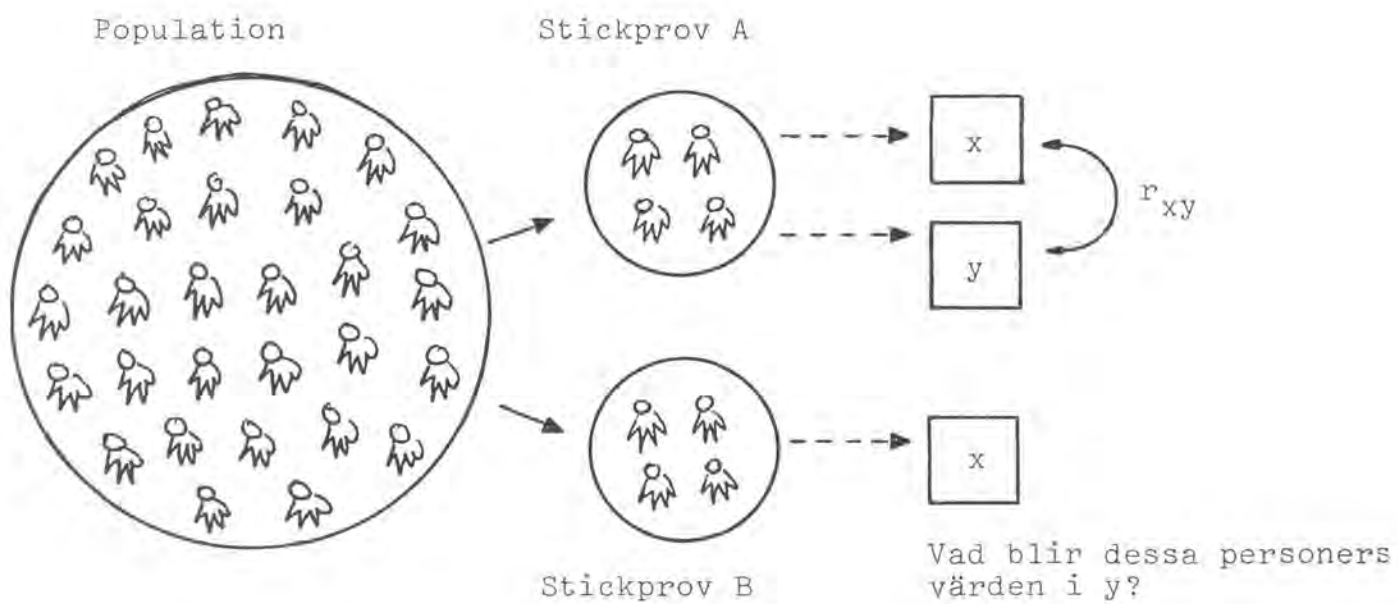
$$58 \pm 1.96 \cdot 6 = 58 \pm 11.8$$

Kan Du förklara varför?



Innan vi slutar detta avsnitt kanske det vore på sin plats att ge en förklaring till varför man överhuvud taget ödslar tid på att räkna ut regressionskoefficienter och regressionslinjer.

Som läsaren förstått hänger begreppet "regression" intimt samman med begreppet "prediktion" och med hjälp av regressionslinjen vill man alltså kunna förutsäga hur en individ betar sig i situationen y utifrån hans beteende i situationen x . För att kunna göra en förutsägelse måste man dock på empirisk väg ha fått fatt på sambandets styrka mellan x och y - ett faktum som vi försökt att åskådliggöra i följande figur.



Läsaren uppmanas att tolka figuren samt ge exempel på vad x och y kan vara för variabler.

Kapitel 4

KOVARIANSANALYSI INTRODUKTION

Kovariansanalys används då man vill undersöka om det finns några skillnader mellan olika gruppers medeltal i en viss kriterievariabel (y), när hänsyn tagits till skillnaderna mellan gruppernas medeltal i en viss kontrollvariabel (x).

Exempel 1: *Finns det några skillnader i skolprestationer mellan elever från olika socialgrupper, när hänsyn tagits till skillnaderna i begåvning?*

Exempel 2: *Finns det några skillnader i kunskapsbehållning mellan två grupper som undervisats med olika metoder, när hänsyn tagits till hur många timmar som grupperna undervisats?*

Exempel 3: *Finns det någon skillnad mellan män och kvinnor i långdistanssimning, när hänsyn tagits till fötternas storlek?*

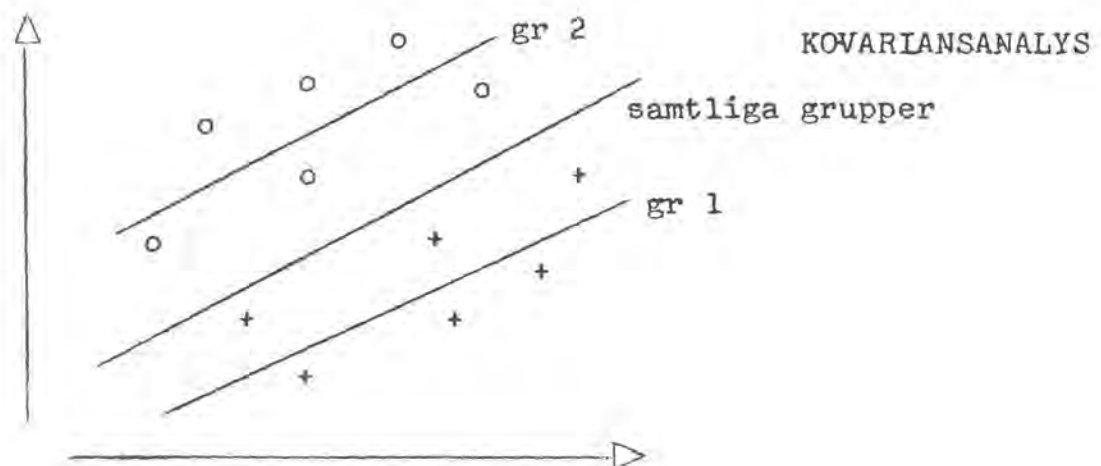

Det sista exemplet är illa valt! Varför?

II SKILLNADER MELLAN VARIANS- OCH KOVARIANSANALYS

Vid en variansanalys baserar sig inomgruppsvariansmättet på de individuella avvikelserna från det egna gruppmedeltalet. Mellangruppsvariansmättet baserar sig på gruppmedeltalets avvikelser från totalmedeltalet.

Vid en kovariansanalys baserar sig inomgruppsvariansmättet på de individuella avvikelserna från den egna gruppens regressionslinje. Mellangruppsvariansmättet baserar sig på skillnaderna mellan respektive gruppers regressionslinjer och en för samtliga grupper gemensam regressionslinje.

Försök att markera de aktuella avvikelserna i nedanstående figurer:



III GRAFISK FRAMSTÄLLNING AV KOVARIANSANALYS

Frågeställning: Finns det några skillnader i standardprovresultat i engelska mellan barn från olika socialgrupper, när hänsyn tagits till skillnader i verbal begåvning?

X = verbalt intelligenstest

Y = standardprov i engelska

Undersökningsresultat:

Soc.gr.	N	\bar{X}	S_x	\bar{Y}	S_y	r_{xy}	b_{yx}
1	100	60	10	60	10	0.70	
2	200	55	10	55	10	0.70	
3	400	45	10	45	10	0.70	

Vad blir totalmedeltalet i X respektive Y?

Vad blir b_{yx} i grupp 1, 2 respektive 3?

Vad blir den genomsnittliga korrelationen respektive regressionen inom grupperna?


Formel för beräkning av väntade medelvärden:

$$\bar{Y}_j = \bar{Y} + b_w (\bar{X}_j - \bar{X})$$

Vad blir de väntade värdena för grupp 1, 2 respektive 3?

Lägg in de väntade värdena i diagrammet.

Stp i engelska



Förbind de väntade värdena med en linje.

Vad är detta för en linje?

Lägg in de funna y-medelvärdena i diagrammet.

Drag en lodrät linje genom totalmedelvärdet.

Transportera de funna värdena parallellt med den tidigare inlagda regressionslinjen, tills de når den lodräta linjen. Härigenom får vi fram de justerade värdena, dvs. de medeltal i engelska som grupperna skulle fått, om det ej funnits några skillnader i verbal begåvning.

De linjer som "transporten" ägt rum på, är ingenting annat än gruppernas egna regressionslinjer.

De justerade medeltalen kan också beräknas direkt ur formeln:

$$\bar{Y}_{j \text{ just}} = \bar{Y}_j - b_w (\bar{X}_j - \bar{X})$$

Kontrollera att formeln ger samma värden, som de ni fått ur diagrammet.

Markera i diagrammet hur stor differensen är mellan grupp 1 och 3 i y-variabeln, dels i ojusterad poäng, dels i justerad poäng. Varför finns det en skillnad även mellan de justerade medeltalen?

Om grupp 1 undervisats med "grammatikmetodik" och grupp 3 med "direktmetodik", kan man då säga att den förra metodiken är överlägsen den senare?

IV SIGNIFIKANSPRÖVNING VID KOVARIANSANALYSER

Liksom en variansanalys utmynnar en kovariansanalys i en F-testning, men med den skillnaden att F-testningen här gäller skillna-

derna mellan justerade medeltal. Om F-kvoten blir signifikant får t-testningar följa, för att man skall få kännedom om, vilka justerade medeltal som skiljer sig signifikant åt.

I allmänhet redovisar man ej en kovariansanalys i grafisk form, utan nöjer sig med att ge de justerade medeltalen samt upplyser om eventuella signifikanser. Beräkningsarbetet vid en kovariansanalys är ej speciellt svårt men ganska tidskrävande, varför det oftast sker med hjälp av EDB. Om man vill räkna med händerna finns beräkningsformler bl.a. i:

Kendall, M.G. (1946) och Lindquist, C.F. (1956).

V VILLKOR FÖR KOVARIANSANALYSER

Kovariansanalysmetodiken förutsätter att ett antal villkor är uppfyllda. Dessa villkor - regressionslinearitet, normalitet, varianshomogenitet m.fl. - finns utförligt behandlade hos Lindquist (a.a.) Här skall vi endast uppehålla oss vid ett villkor - kravet på regressionshomogenitet.

För att kunna använda kovariansanalysmetoden på ett meningsfullt sätt förutsätts att gruppernas regressionslinjer har samma lutning. Detta kan man pröva genom en variansanalys av inomgruppsresultaten, där inomgruppsvariansmättet bygger på individernas avvikelser från de egna gruppernas reella regressionslinjer och mellangruppsvariansmättet på avvikelserna mellan dessa linjer och linjer som går genom respektive gruppmedeltal, men som alla har samma lutning som den gemensamma inomgruppsregressionslinjen. Om F-kvoten i detta fall blir signifikant är kravet på parallellitet ej uppfyllt, och resultatet av kovariansanalyser blir vanskligt att tolka.


Texten ovan kan möjligen uppfattas som något svårsmält, varför vi ger följande exemplifiering:

I vårt tidigare exempel var samtliga tre gruppers regressionskoefficienter 0.70. Antag i stället att koefficienterna varit följande:

Gr	N	b_{yx}
1	100	0.66
2	200	0.68
3	400	0.72

Även i detta fall blir den genomsnittliga inomgruppsregressionskoefficienten (b_w) = 0.70. Varför?

I figuren nedan återges gruppernas 1 och 3 reella regressionslinjer - $b_{yx} = 0.66$ respektive 0.72 - samt en linje genom vardera gruppmedeltal med samma lutning som den gemensamma inomgruppsregressionslinjen ($b_w = 0.70$). I figuren är lutningsskillnaderna mellan linjerna klart överdrivna.



Markera i figuren de avstånd som ligger till grund för inom- respektive mellangrupsvariansmättet vid en F-testning av gruppregressionslinjernas parallellitet - dvs. vid en prövning av regressionshomogeniteten.

Ifall F-kvoten ej är signifikant, kan vi således utföra en kovariansanalys, eller hur?

Vad skall vi då göra om F-kvoten blir signifikant? Vilka konsekvenser har detta? Hur ser regressionslinjerna ut? Kan vi överhuvudtaget få några värdefulla upplysningar under sådana förhållanden?

VI NÅGRA AVSLUTANDE SYMPUNKTER

- a) Kovariansanalysmetoden är en form av statistisk kontroll som man tillgriper när det är omöjligt eller olämpligt att använda experimentell kontroll.

Giv några exempel på sådana situationer.

- b) Kovariansanalysmetoden kan även tillämpas i strikt experimentella undersökningar.

Vilken funktion har metoden då?

- c) För att det skall vara meningsfullt att använda kovariansanalysmetoden måste det finnas en viss korrelation mellan x- och y-variabeln.


Varför?

Hur hög bör korrelationen vara?

- d) Om det finns reliabilitetsbrister i x-variabeln, kan kovariansanalysmetoden ge klart felaktiga resultat. En korrektionsmetod har emellertid utarbetats av Härnqvist, vilken finns beskriven i Svensson (1971, s. 153-157).

Tabell 1: Normalfördelningen

Andel av fördelningen(s yta) som ligger till vänster om (under) ett visst z -värde.




z	Andel (i %) som ligger t.v. om z	z	Andel (i %) som ligger t.v. om z	z	Andel (i %) som ligger t.v. om z
-3,0	0,1	-1,0	15,9	+1,1	86,4
-2,9	0,2	-0,9	18,4	+1,2	88,5
-2,8	0,3	-0,8	21,2	+1,3	90,3
-2,7	0,4	-0,7	24,2	+1,4	91,9
-2,6	0,5	-0,6	27,4	+1,5	93,3
-2,5	0,6	-0,5	30,9	+1,6	94,5
-2,4	0,8	-0,4	34,5	+1,7	95,5
-2,3	1,1	-0,3	38,2	+1,8	96,4
-2,2	1,4	-0,2	42,1	+1,9	97,1
-2,1	1,8	-0,1	46,0	+2,0	97,7
-2,0	2,3	0	50,0	+2,1	98,2
-1,9	2,9	+0,1	54,0	+2,2	98,6
-1,8	3,6	+0,2	57,9	+2,3	98,9
-1,7	4,5	+0,3	61,8	+2,4	99,2
-1,6	5,5	+0,4	65,5	+2,5	99,4
-1,5	6,7	+0,5	69,1	+2,6	99,5
-1,4	8,1	+0,6	72,6	+2,7	99,6
-1,3	9,7	+0,7	75,8	+2,8	99,7
-1,2	11,5	+0,8	78,8	+2,9	99,8
-1,1	13,6	+0,9	81,6	+3,0	99,9
		+1,0	84,1		

Tabell 2: Normalfördelningen


Andel av fördelningen(s yta) som ligger mellan vissa z -värden.

z	Andel som ligger mellan z -värdena
$\pm 1,64$	90 %
$\pm 1,96$	95 %
$\pm 2,33$	98 %
$\pm 2,58$	99 %



Tabell 3: t-fördelningar

Tabellen anger för olika frihetsgrader (df) de t -värden som mellan sig avgränsar angivna andelar av fördelningen(s yta).



Frihets- grader (df)	Andel mellan $-t$ och $+t$			
	90 %	95 %	98 %	99 %
		t		
1	6,31	12,71	31,82	63,76
2	2,92	4,30	6,96	9,92
3	2,35	3,18	4,54	5,84
4	2,13	2,78	3,75	4,60
5	2,01	2,57	3,36	4,03
6	1,94	2,45	3,14	3,71
7	1,89	2,36	3,00	3,50
8	1,86	2,31	2,90	3,35
9	1,83	2,26	2,82	3,25
10	1,81	2,23	2,76	3,17
11	1,80	2,20	2,72	3,11
12	1,78	2,18	2,68	3,05
13	1,77	2,16	2,65	3,01
14	1,76	2,14	2,62	2,98
15	1,75	2,13	2,60	2,95
16	1,75	2,12	2,58	2,92
17	1,74	2,11	2,57	2,90
18	1,73	2,10	2,55	2,88
19	1,73	2,09	2,54	2,86
20	1,72	2,09	2,53	2,84
21	1,72	2,08	2,52	2,83
22	1,72	2,07	2,51	2,82
23	1,71	2,07	2,50	2,81
24	1,71	2,06	2,49	2,80
25	1,71	2,06	2,48	2,79
26	1,71	2,06	2,48	2,78
27	1,70	2,05	2,47	2,77
28	1,70	2,05	2,47	2,76
29	1,70	2,04	2,46	2,76
30	1,70	2,04	2,46	2,75
40	1,68	2,02	2,42	2,70
60	1,67	2,00	2,39	2,66
100	1,66	1,98	2,36	2,63
500	1,63	1,96	2,33	2,59
∞ ($t = z$)	1,64	1,96	2,33	2,58
	10 %	5 %	2 %	1 %
	Andel utanför $-t$ och $+t$			

LITTERATURREFERENSER

- Edwards, A.L. (1960) Experimental Design in Psychological Research.
(Rev. ed.) New York: Holt, Rinehart & Winstone.
- Ferguson, G. (1966) Statistical Analysis in Psychology and Education. New York: Mc Graw-Hill.
- Kendall, M.G. (1946) The Advanced Theory of Statistics. Vol. II.
London: Griffin.
- Lindquist, C.F. (1956) Design and Analysis of Experiments in Psychology and Education. Boston: Houghton, Mifflin.
- Svensson, A. (1971) Relative Achievement. School performance in relation to intelligence, sex and home environment. Stockholm: Almqvist & Wiksell.
- Walker, H.M. & Lev, J. (1953) Statistical Inference. New York: Holt, Rinehart & Winston.
- Vejde, O. (1965) Hur man räknar statistik. Stockholm: Natur och Kultur.

ÖVNINGUPPGIFTERI FLERVALSFRÅGOR

1. Sambandet mellan intelligens (x) och skolprestation (y) uppgår i en undersökning till 0.70 (r_{xy}). Härav följer att det finns en viss spridning runt regressionslinjen. Vilka data förutom korrelationskoefficienten, behöver du för att beräkna denna spridning ($s_{y \cdot x}$)?
 - a) s_y
 - b) s_x
 - c) \bar{x}
 - d) \bar{y}

2. I en undersökning vill man studera hur tre olika undervisningsmetoder i engelska påverkar språkkunskaperna bland pojkar respektive flickor. Vilken statistisk analysmetod bör man använda:
 - a) en-vägs variansanalys
 - b) två-vägs variansanalys
 - c) tre-vägs variansanalys
 - d) kovariansanalys

3. Vilket av följande villkor behöver inte vara uppfyllt för att man skall kunna uttrycka sambandet mellan två variabler i form av en produktmomentkorrelation?
 - a) De båda variablerna skall vara kontinuerliga
 - b) Fördelningarna i de båda variablerna skall vara lika
 - c) Spridningarna i de båda variablerna skall vara lika
 - d) Sambandet mellan de båda variablerna skall vara linjärt

4. Vid en kovariansanalys undersöker man differenserna mellan:
 - a) funna medeltal
 - b) justerade medeltal
 - c) funna varianser
 - d) justerade varianser

5. I en undersökning - baserad på ett stickprov bestående av 18 treåringar - kom man fram till att sambandet mellan den tid föräldrarna samtalar med sina barn och barnens ordförråd var +0.60 (produktmomentkorrelation). Vid signifikanstestningen av denna korrelation erhöll man följande värde:
- a) 2.50
 - b) 2.75
 - c) 3.00
 - d) 3.25
6. Vilket av följande påståenden är riktigt beträffande en-vägs variansanalys?
- a) Variansmåttan är additiva
 - b) Mellangruppskvadratsumman skall divideras med N-k frihetsgrader
 - c) Totala antalet frihetsgrader är lika med totala antalet individer
 - d) Vid testning av skillnader mellan enskilda medeltal kan både t- och F-test användas
7. Vilket av nedanstående krav behöver inte alls vara uppfyllt för att man skall få tillämpa variansanalysmetodiken?
- a) Kravet på additivitet
 - b) Kravet på normalitet
 - c) Kravet på varianshomogenitet
 - d) Kravet på medeltalsekvivalens
8. I en undersökning erhåller man följande värden:
- $$\bar{X} = 50, s_x = 12$$
- $$\bar{Y} = 70, s_y = 18$$
- $$r_{xy} = 0.60, N = 400$$
- Detta innebär att spridningen runt regressionslinjen ($s_{y,x}$) blir:
- a) 8.2
 - b) 10.4
 - c) 12.8
 - d) 14.4

9. I en undersökning ingick tre grupper om vardera 25 individer. För att undersöka om det finns några skillnader mellan grupperna görs en variansanalys, varvid man erhåller följande resultat: Mellangruppskvadratsumman = 272, Inomgruppskvadratsumman = 1440, samt ett F-värde som uppgår till:
- 3.20
 - 4.40
 - 5.60
 - 6.80
10. Korrelationen mellan poängen på ett standardiserat kunskapsprov i engelska och lärarens betyg i samma ämne uppgår till 0.80. Medeltalet på kunskapsprovet är 30 poäng och medelbetyget 3.0. Spridningen på kunskapsprovet är 10 och betygets spridning 1.0. Om man använder kunskapsprovet som oberoende variabel och betyget som beroende variabel blir regressionskoefficienten:
- 0.008
 - 0.080
 - 0.800
 - 8.00
11. För att man skall få tillämpa kovariansanalysmetoden måste kravet på regressionshomogenitet vara uppfyllt. Detta krav innebär att:
- gruppernas justerade medeltal är lika
 - gruppernas regressionslinjer är parallella
 - grupperna är homogent sammansatta
 - gruppernas spridningar är lika
12. Vilket av nedanstående påståenden är felaktigt? Varians- och kovariansanalysmetoden:
- är båda parametriska metoder
 - brukas båda vid multipla medeltalsjämförelser
 - kan båda användas vid såväl sambandsundersökningar som experimentella undersökningar
 - utmynnar båda i en testning av skillnaderna mellan justerade medeltal

II ÖVRIGA UPPGIFTER1. Frågor i anslutning till variansanalysmetoden:

- Vilka är de väsentligaste skillnaderna mellan en-vägs och två-vägs variansanalys?
- Vad menas med kravet på varianshomogenitet?
- Vad är ett inomgruppsvariansomått?
- Vad innebär det, om man får ett F-värde som är betydligt större än 1?
- Giv exempel på en 4 x 3 x 2 design

2. För att undersöka om det finns några skillnader i bensinförbrukning mellan tre olika bilmärken, väljer man slumpmässigt ut tre bilar av vardera märket. Varje bil körs 10 mil, varefter bensinåtgången kontrolleras. Bilarnas förbrukning återges i tabellen nedan. Undersök om det finns några signifikanta skillnader på 5%-nivån mellan bilmärken.

Bilmärke	A	B	C
Bensinförbrukning	8	9	10
per bil	9	10	11
	10	11	12

3. I en undersökning rörande sambandet mellan längd (x) och vikt (y) bland ynglingar i 18-årsåldern har man fått fram följande data:

$$\begin{array}{ll} \bar{X} & = 175 & S_x & = 5 \\ \bar{Y} & = 70 & S_y & = 10 \\ r_{xy} & = 0.50 & N & = 77 \end{array}$$

- Sambandet mellan de båda variablerna är uttryckt i form av en produktmomentkorrelation. Vilka krav måste vara uppfyllda för att man skall få använda detta sambandsmått?
- Beräkna regressionskoefficienten (b_{yx}).
- Beräkna spridningen runt regressionslinjen ($S_{y \cdot x}$)
- Vilken nytta har man av att känna till detta spridningsmått?

4. För att undersöka om det finns några skillnader i längd mellan pojkar i 13-, 14-, 15-, 16- och 17-årsåldern väljer man slumpmässigt ut 100 pojkar från varje åldersgrupp. Undersökningen ger följande resultat.

Åldersgrupp	Genomsnittlig längd (\bar{X})
13	159 cm
14	167 cm
15	173 cm
16	175 cm
17	176 cm

Mellangrupperkvadratsumman = 2448

Inomgrupperkvadratsumman = 8910

Undersök om det finns några signifikanta skillnader mellan åldersgrupperna samt mellan vilka åldersgrupper som eventuella signifikanta differenser är belägna. Samtliga testningar görs på 1 %-nivån.

5. För att undersöka om det finns någon skillnad mellan Sveriges bästa manliga och kvinnliga höjdhoppare, när hänsyn tagits till differensen i kroppslängd, konstanthåller man längden på statistisk väg med hjälp av kovariansanalysmetoden. Nedan följer vissa data från undersökningen.

Kön	Antal	Kroppslängd		Höjdhopsresultat	
		\bar{X}	s_x	\bar{Y}	s_y
Män	50	184	4	203	8
Kvinnor	50	172	4	168	8

Korrelationen mellan kroppslängd och höjdhopsresultat uppgår till 0.60 bland både män och kvinnor.

- Är den funna korrelationen signifikant?
- Vad blir männens respektive kvinnornas justerade medelvärden i höjdhopp?

6. För att få veta om det finns någon skillnad i sjukfrånvaro mellan manliga och kvinnliga tjänstemän i olika åldersklasser vid ett större företag går man tillväga på följande sätt: De anställda indelas i fyra åldersklasser, varefter man slumpmässigt väljer ut 25 män och 25 kvinnor från varje klass och ser efter hur många dagar dessa personer varit frånvarande under de två senaste månaderna. Det genomsnittliga antalet sjukdagar samt vissa andra data följer nedan. Hur skall man tolka undersökningsresultaten?

	Ålder			
	under 30	30 - 40	40 - 50	över 50
män	3.7	2.2	1.4	0.5
kvinnor	7.2	4.6	1.8	0.6

Radkvadratsumman	=	63
Kolumnkvadratsumman	=	270
Interaktionskvadratsumman	=	324
Inom-cellskvadratsumman	=	1728

7. För att undersöka effekten av olika typer av föräldrautbildning med avseende på mannens engagemang i spädbarnsskötsel går man tillväga på följande sätt: 30 blivande barnafäder fördelades slumpmässigt på tre grupper. Grupp I erhåller ingen som helst utbildning. Grupp II får åhöra föreläsningar i barnpsykologi under sammanlagt 15 timmar. Grupp III får delta i en 10-poängskurs i barnkunskap vid pedagogiska institutionen. All undervisning är avslutad innan barnafödelsen. Två månader efter denna tar man reda på hur många timmar per dag som respektive fader ägnar åt sitt barn. Härvid får man fram de data som återges i tabellen nedan. Hur vill Du tolka utfallet av undersökningen?

Grupp	I	II	III
Antal timmar barnavårdande aktiviteter	0	0	0
	0	0	1
	0	1	1
	0	1	1
	1	1	2
	1	2	2
	1	2	3
	2	2	3
	2	3	3
	3	3	4

8. 18 personer, fördelade på tre grupper, har deltagit i en kurs i lästeknik. Grupperna har fått något varierande undervisning. Efter kursens slut gavs ett läsprov. Nedan redovisas hur många fel varje deltagare hade på detta prov. Undersök om det finns några signifikanta skillnader på 5 %-nivå mellan grupperna.

Grupp	I	II	III
Antal fel	1	1	1
per deltagare	1	2	2
	2	3	3
	2	3	4
	3	4	5
	3	5	6

9. I en undersökning rörande sambandet mellan intelligens (X) och skolprestation (Y) har man fått fram följande data:

$$\begin{array}{ll} \bar{X} & = 42 & s_x & = 8 \\ \bar{Y} & = 58 & s_y & = 12 \\ r_{xy} & = 0.80 & N & = 38 \end{array}$$

- Signifikanstesta korrelationskoefficienten
 - Hur tolkar Du utfallet av signifikanstestningen?
 - Beräkna regressionskoefficienten (b_{yx})
 - Beräkna spridningen runt regressionslinjen ($s_{y \cdot x}$)
 - En elev har 47 poäng på intelligenstestet. Vilket blir hans väntade värde (Y') på skolprestationstestet?
10. Frågor i anslutning till kovariansanalysmetoden:
- Kovariansanalysmetoden är en form av statistisk kontroll som man tillgriper när det är omöjligt eller olämpligt att använda experimentell kontroll. Giv exempel på en sådan situation.
 - Kovariansanalysmetoden kan även tillämpas i strikt experimentella undersökningar. Vilken funktion har metoden då?
 - För att det skall vara meningsfullt att använda metoden måste det finnas en viss korrelation mellan x- och y-variabeln. Varför?
 - Metoden ställer krav på regressionslinearitet och regressionshomogenitet. Vad innebär dessa krav?

11. För att komma tillrätta med sömnlösningssproblemet använder man sig av olika tekniker. I en undersökning studerade man tre olika terapeutiska metoder:

- I) Hypnosbehandling
 II) Sömlösningssmatta
 III) Medicinska preparatet B 14.

15 sömnlösare i 10-årsåldern fördelades slumpmässigt på tre lika stora grupper, varefter grupperna erhöi olika behandling. Försöket pågick en månad, varefter man under en vecka noterade antalet nätter utan sömnlösning. Tre individer avbröt behandlingen. Resultaten för de övriga framgår av tabellen. Vilka slutsatser vill Du dra utifrån undersökningens utfall?

Grupp	I	II	III
Antal nätter utan sömnlösning	4	3	2
	5	4	3
	6	5	4
		6	5
			6

12. I en tandvårdsundersökning önskade man belysa vilken betydelse som användningen av fluoriserad tandkräm respektive bruket av tandsticker har för att motverka uppkomsten av karies. Dessutom vill man veta om det fanns någon interaktion mellan de båda behandlingsmetoderna. Till undersökningen utvaldes 200 ungdomar, vilka slumpmässigt fördelades på fyra lika stora undergrupper. Under ett år utsätts sedan försökspersonerna för någon av de fyra behandlingskombinationerna, varefter man undersöker hur många tecken på karies (hål) som varje försöksperson har. Nedan redovisas det genomsnittliga antalet hål för varje grupp samt vissa andra data. Nu är det Din uppgift att analysera undersökningens resultat.

	Tandkräm utan fluor	Tandkräm med fluor
Använder ej tandsticker	$\bar{x}_{11} = 3.0$	$\bar{x}_{12} = 2.2$
Använder tandsticker	$\bar{x}_{21} = 1.4$	$\bar{x}_{22} = 0.8$

Radkvadratsumman	=	31.5
Kolumnkvadratsumman	=	15.0
Interaktionskvadratsumman	=	4.5
Inom-cellskvadratsumman	=	294.0

13. I en undersökning plockade man slumpmässigt ut fem elever från vardera årskurs 1, 2, 3, 4 och 5. Eleverna fick genomgå ett prov i trafikkunskap som innehöll 40 uppgifter. Elevernas resultat framgår nedan. Undersök om det finns några signifikanta skillnader mellan årskurserna samt mellan vilka årskurser som eventuella signifikanta differenser är belägna. Samtliga testningar görs på 1 %-nivån.

Årskurs	1	2	3	4	5
Antal poäng	5	4	17	15	35
	6	7	26	18	27
	12	9	17	21	29
	12	9	20	26	30
	7	14	12	20	25

Mellangruppskvadratsumman = 1521,44

Inomgruppskvadratsumman = 326,40

14. För att undersöka om det finns några skillnader i reparationskostnader mellan de fyra bilfabrikaten Bierwagen, Dunderbird, Korven och Tavarich, går man tillväga på följande sätt. Man väljer ut 20 bilar av vardera fabrikatet. Samtliga bilar är fem år gamla. De har emellertid körts olika långt, varför man konstanthåller körsträckan med hjälp av kovariansanalys. I tabellen nedan redovisas antalet körda mil (x), reparationskostnaderna (y) samt korrelationen mellan dessa båda variabler.

Bilmärke	N	\bar{X}	s_x	\bar{Y}	s_y	r_{xy}
Bierwagen	20	10.000	2.000	7.000	2.000	0.46
Dunderbird	20	12.000	2.000	9.000	2.000	0.48
Korven	20	14.000	2.000	6.000	2.000	0.52
Tavarich	20	16.000	2.000	14.000	2.000	0.54

- Beräkna de väntade y -medelvärdena
- Vilka upplysningar ger oss dessa väntade värden?
- Beräkna de justerade y -medelvärdena
- Vilken information kan de justerade värdena ge?

15. Vid ett handelsinstitut förekommer två undervisningsmetoder i maskinskrivning, "snuddmetoden" och "slagmetoden". Vilken metod är mest effektiv? För att klarlägga detta låter man 200 elever utbilda sig enligt "snuddmetoden" och 200 enligt "slagmetoden". Inom vardera gruppen får 100 elever träna på elektriska maskiner och 100 på icke elektriska maskiner. Samtliga får träna under 90 timmar, varefter man ger ett prov - man kontrollerar hur många nedslag varje elev klarar under en minut. Nedan redovisas det genomsnittliga antalet nedslag för var och en av de fyra undergrupperna samt vissa andra data. Med utgångspunkt från dessa skall Du signifikanstesta rad-, kolumn- och interaktionseffekten. Välj själv signifikansnivå samt ge en kortfattad redogörelse för utfallet av undersökningen.

	Snuddmetoden	Slagmetoden
Elektrisk skrivmaskin	$\bar{X}_{11.} = 190$	$\bar{X}_{12.} = 160$
Icke elektrisk skrivmaskin	$\bar{X}_{21.} = 150$	$\bar{X}_{22.} = 185$

Radkvadratsumman	= 1200
Kolumnkvadratsumman	= 400
Interaktionskvadratsumman	= 4000
Inom-cellskvadratsumman	= 158 400

16. I tabellen nedan återges antalet fel i ett psykomotoriskt prov för fyra grupper av individer som testats under olika experimentella förhållanden. Testa nollhypotesen:

$$\mu_1 = \mu_2 = \mu_3 = \mu_4$$

Signifikansnivå: 5 %

Grupp	I	II	III	IV
Antal fel	16	24	16	25
	7	6	15	19
	19	15	18	16
	24	25	19	17
	31	32	6	42
		24	13	45
		29	18	

17. För att undersöka om det finns någon skillnad i studieprestationerna i matematik mellan elever från olika regioner i Sverige går man tillväga på följande sätt: Landet indelas i större tätorter, mindre tätorter och glesbygd. Från var och en av de båda förstnämnda kategorierna utväljes slumpvis 200 elever och från den sistnämnda 100 elever. Samtliga elever tillhör årskurs 6. Vid vårterminens slut insamlas matematikbetygen för de berörda eleverna. För att kontrollera eventuella skillnader i begåvning har eleverna dessförinnan fått genomgå ett induktivt begåvningsstest av sifferserietyp. Vissa data från undersökningen framgår nedan:

Tabell 1: Medeltal och spridningar

Region	Antal	Testresultat		Betyg	
		\bar{X}	s_x	\bar{Y}	s_y
Större tätorter	200	21	5	3.04	1.00
Mindre tätorter	200	20	5	3.05	1.00
Glesbygd	100	18	5	3.07	1.00

Tabell 2: Korrelationer mellan testresultat och betyg

Region	Antal	r_{xy}
Större tätorter	200	0.62
Mindre tätorter	200	0.61
Glesbygd	100	0.54

Din uppgift är nu:

- Visa med hjälp av grafisk framställning skillnaderna mellan ortstyperna i matematikbetyg, när hänsyn tagits till skillnader i begåvning.
- Kontrollera de grafiska uppgifternas riktighet med hjälp av relevanta formler.

11) $F = 0.53$ H_0 accepteras

12) $F_r = 21$; H_0 förkastas

$F_c = 10$; H_0 förkastas

$F_i = 3$; H_0 accepteras

13) $F = 23.34$ H_0 förkastas

5 4 3 2 1

14)	<u>Bilmärke</u>	<u>Väntade värden</u>	<u>Justerade värden</u>
	Bierwagen	7.500	8.500
	Dunderbird	8.500	9.500
	Korven	9.500	5.500
	Tavarich	10.500	12.500

15) $F_r = 3.00$ kritiskt värde

$F_c = 1.00$ df 1,396

$F_i = 10.00$ 5 % - 3.86

1 % - 6.70

Endast interaktionseffekten är signifikant

16) $F = 2.06$ H_0 accepteras

17)	b)	<u>Region</u>	<u>Väntade värden</u>	<u>Justerade värden</u>
		Större tätorter	3.17	2.92
		Mindre tätorter	3.05	3.05
		Glesbygd	2.81	3.31

