

# Föreläsning 7 och 8: Regressionsanalys\*

Pär Nyman

3 februari 2014

Det här är anteckningar till föreläsning 7 och 8. Båda föreläsningarna handlar om regressionsanalys, så jag slog ihop dem till ett gemensamt dokument och gjorde samma sak med bilderna till presentationen. Delar av texten är ganska skissartad, men så är det ju också anteckningar. Läsanvisningar: Kapitel 8 i Teorell och Svensson.

## 1 Regressionsanalys

Regressionsanalysen är den kvantitativa samhällsvetenskapens i särklass viktigaste verktyg. Oavsett om man skriver en kvantitativ uppsats eller läser en bra forskningsartikel med mycket statistik är det oftast regressionsanalys som används. Det finns hur mycket som helst man kan lära sig om att göra regressioner, men man kommer ganska långt med de grunder vi lär ut på den här kursen. Eftersom regressionsanalys är så pass vanligt vill jag verkligen rekommendera även de som inte tycker att siffror är deras grej att lära sig grunderna. Ni kommer att stöta på många regressioner i era framtida studier och arbetsliv. För att kunna bedöma trovärdigheten i deras resultat är det viktigt att ni förstår vad de har gjort och var svagheterna ligger i deras analys.

Med lite fantasi kan man besvara de flesta typer av frågor med regressionsanalys, men i regel studerar vi kausala samband sådana att värdet på en variabel påverkar värdet på en annan variabel.

Detta avsnitt innehåller en del repetition från den tidigare föreläsningen, men eftersom regressionsanalys är nytt för de flesta tror jag inte att det skadar.

### 1.1 Regressionsekvationen

Att genomföra en regressionsanalys är samma sak som att skatta de olika parametrarna i regressionsekvationen. Om ni minns ”den räta linjens ekvation” ( $y = kx + m$ ) från gymnasiematematiken, så är det här i grunden samma sak.

---

\*Denna föreläsning bygger vidare på tidigare föreläsningar av Elin Bjarnegård och Pär Zetterberg.

Vi tänker oss att den beroende variabeln ( $y$ ) är en linjär funktion av en eller flera oberoende variabler ( $x$ ), så att när  $x$  ökar med 1 så förändras  $y$  med  $b$ . Genom att skatta värdet av interceptet ( $a$ ) och regressionskoefficienten ( $b$ ) kan vi både beskriva sambandet mellan variablerna och göra prediktioner av den beroende variabeln. Regressionsekvationen, vilken även anger våra prediktioner, är dock sällan en perfekt beskrivning av verkligheten. Även om vi känner till värdet på den oberoende variabeln ( $x$ ) kommer de observerade värdena på den beroende variabeln ( $y$ ) skilja sig från modellens prediktioner. Vi säger att observationen består av en prediktion ( $a + bx$ ) plus en felterm eller residual ( $e$ ). Regressionsekvationen kan således skrivas

$$\begin{aligned}y &= a + bx + e \\ \hat{y} &= a + bx\end{aligned}\tag{1}$$


där

$y$  = Beroende variabel  
 $a$  = Konstant eller intercept  
 $b$  = Regressionskoefficient  
 $x$  = Oberoende variabel  
 $e$  = Felterm eller residual

Ibland skriver man en ekvation för  $\hat{y}$  i stället för  $y$ . Hatten över  $y$  står för att det är en prediktion, en gissning. Eftersom våra prediktioner är identiska med vår regressionsmodell behöver vi inte inkludera någon felterm i ekvationen. Feltermen inkluderas bara när vi har faktiska observationer till vänster om likamedtecknet.

Vi kan också illustrera allt detta grafiskt. Figuren här är hämtad från en kolumn i *The New England Journal of Medicine* och visar den genomsnittliga årskonsumtionen av choklad samt andelen Nobelpristagare för ett urval av länder. De blå prickarna är alltså länder. Som synes har länder med hög chokladkonsumtion (ligger långt åt höger i figuren) också en högre andel Nobelpristagare (är placerade högt upp i figuren). Detta innebär förstås inte att sambandet är kausalt (att chokladkonsumtionen påverkar andelen Nobelpristagare), även om det är vad artikelförfattarna något skämtsamt argumenterar för.

$Y$  är värdet på den beroende variabeln, alltså var observationerna placerar sig på den vertikala  $y$ -axeln.  $X$  är värdet på de oberoende variablerna och således var observationerna placeras längs den horisontella  $x$ -axeln. När  $x = 0$  gäller att  $\hat{y} = a$ . Konstanten är därför det värde vid vilket regressionslinjen skär  $y$ -axeln, alltså vår prediktion av  $y$  när värdet på  $x$  är 0. Regressionskoefficienten är den förväntade förändringen av  $y$  när  $x$  ökar med 1. I figuren illustreras det med att när chokladkonsumtionen ökar från 5 till 6 kg så stiger



antalet Nobelpristagare (per 10 milj invånare) från 10 till 12.8. Residualerna utgörs av varje observations avvikelse från regressionslinjen.

## 1.2 Passningsmått

När man analyserar olika typer av samband kan det ofta vara av värde att skilja mellan storleken på en kausal effekt och modellens passning. Med en effekts storlek menas hur stor påverkan en viss förändring i den oberoende variabeln ( $x$ ) har på den beroende variabeln ( $y$ ), alltså hur stor regressionskoefficienten är. Med modellens passning avses hur väl regressionsmodellen sammanfattar sambandet mellan oberoende och beroende variabel. Intuitivt kan vi förstå en modells passning på följande sätt: desto mindre avståndet är mellan de faktiska observationerna och regressionslinjen desto bättre är modellens passning. Passning kallas ibland förklaringskraft.

Passningen mäts med olika passningsmått, vilka anger hur väl vår modell beskriver den data vi har observerat. God passning innebär att observationerna ligger nära regressionslinjen, vilket är samma sak som att vi kan göra bra prediktioner med hjälp av vår modell om vi känner till värdena på de oberoende variablerna. Dålig passning innebär att observationerna ligger långt bort från regressionslinjen, så att vi i genomsnitt gör stora fel när vi med hjälp av vår modell försöker gissa värdena på den beroende variabeln.

De två viktigaste passningsmått är regressionens standardfel och  $R^2$ . Båda dessa mått mäter i grunden samma sak – storleken på residualerna –

men uttrycker passningen på olika skalor. Vilket mått som lämpar sig bäst beror helt på vilket syfte man har och vad man vill jämföra med. Ofta är det en bra idé att ange båda måtten.

Standardfelet anger hur långt ifrån regressionslinjen som residualerna ligger ”i genomsnitt” och är alltid mätt i samma enhet som den beroende variabeln.  $R^2$  kan anta värden mellan 0 och 1 och anger hur stor andel av variationen i den beroende variabeln som vår modell kan förklara, alltså hur mycket vår modell bidrar till att minska residualerna. Nedan följer en lite mer utförlig beskrivning av de båda passningsmåtten.

Regressionens standardfel är *nästan* samma sak som den genomsnittliga avvikelsen från regressionslinjen. Även om det inte är exakt samma sak, är det ofta så man tolkar måttet. Således är det också helt ok för er att uttrycka er så. För att återknyta till exemplet med Nobelpris så var standardfelet i den regressionen 6,6. Vi uttrycker det som att de observerade värdena i genomsnitt avviker från modellens prediktioner med 6,6 Nobelpristagare per 10 miljoner invånare. Precis som med regressionskoefficienterna måste vi alltid bedöma standardfelet i förhållande till skalan. Hade den beroende variabeln varit mätt som antal Nobelpristagare per invånare – i stället för per 10 miljoner invånare – hade standardfelet blivit 0.00000066, men passningen hade fortfarande varit lika bra.

Ni behöver inte känna till eller förstå ekvationen för regressionens standardfel, men en del lär sig ändå mycket av att se den. RSS står för summan av de kvadrerade feltermerna (Residual Sum of Squares),  $n$  för antalet observationer och  $k$  för antalet oberoende variabler (så att  $n - 1 - k$  blir antalet frihetsgrader).

$$\text{Standardfel} = \sqrt{\frac{RSS}{n - 1 - k}} = \sqrt{\frac{\sum(e_i^2)}{n - 1 - k}} = \sqrt{\frac{\sum(y_i - \hat{y}_i)^2}{n - 1 - k}} \quad (2)$$

Det vanligaste passningsmättet är  $R^2$ , vilket brukar beskrivas som andelen förklarad variation i den beroende variabeln.  $R^2$  kan anta värden mellan 0 (vår modell förklarar ingenting) och 1 (vår modell förklarar 100 procent av variationen i den beroende variabeln). För att återigen använda vårt tidigare exempel, så var  $R^2$  då 0,6. Detta uttrycker vi som att skillnader i chokladkonsumtion kan ”förklara” 60 procent av variationen mellan länder i antalet Nobelpristagare. Anledningen till att jag skriver förklara med citationstecken är att endast en samvariation mellan två variabler sällan betraktas som en fullgod förklaring. Exempelvis har vi inte isolerat sambandet från andra möjliga förklaringar eller funderat särskilt mycket på vilken mekanism som skulle kunna ge upphov till detta samband.

På samma sätt som med standardfelet behöver ni inte känna till eller förstå ekvationen för  $R^2$ . TSS står för summan av avvikelserna från medelvärdet (Total Sum of Squares), vilket är samma sak som den totala variationen i den beroende variabeln.

$$R^2 = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y}_i)^2} \quad (3)$$

När vi tolkar passningsmått är det bra att komma ihåg följande tre saker.

- Vad som är högt och lågt beror som alltid på vad vi har att jämföra med. Studenter har ofta orimligt höga förväntningar på vad våra modeller kan åstadkomma.
- Stirra er inte blinda på passningsmått. Vårt mål är sällan att göra de bästa prediktionerna. Vanligare att vi är intresserade av ett kausalt samband.
- Då är det viktigare hur stor effekten är samt huruvida den är statistiskt signifikant, alltså om samvariationen i vårt urval kan bero på slumpen.

När man adderar en variabel till en regressionsmodell kommer  $R^2$  alltid att öka, även om den inte har något med den beroende variabeln att göra. För att korrigera för detta bör man i regel använda ett mått som kallas för justerat  $R^2$  när man gör en multivariat regression. Skillnaden är att justerat  $R^2$  innehåller en korrigering för antalet variabler i modellen (i förhållande till antalet observationer). Justerat  $R^2$  stiger endast om man adderar en variabel som bidrar mer till modellen än vad vi skulle förvänta oss om variabeln inte hade något samband med övriga variabler. Det är vanligt att även justerat  $R^2$  uttrycks som andel av variationen i den beroende variabeln som modellen förklarar. Även om det inte är helt korrekt är det ok för er att tolka båda måtten så. Vill ni vara mer korrekta kan ni lägga till ”justerat för antalet frihetsgrader”.

## 2 Statistisk signifikans – från urval till population

En fråga har säkert flera av er redan har funderat över: Hur kan vi veta att de regressionsresultat vi finner i urvalet också gäller i den totala populationen som vi i slutändan vill uttala oss om? Hur vet vi exempelvis att det positiva samband mellan ideologisk position och inställningen till behovet av ökad jämställdhet mellan könen som vi fann i vårt urval också gäller bland alla röstberättigade svenskar? Med andra ord, hur generaliserar man sina kausala resonemang?

Ett ofta förekommande fall är att vi är intresserade av att ta reda på om det finns ett samband mellan två variabler  $x$  och  $y$  i populationen. Men då vi av tids- och resursskäl inte kan undersöka hela populationen tvingas vi nästan alltid arbeta med urval. Grundlogiken skiljer sig inte från hur man gör detta i det univariata fallet, alltså när man vill generalisera beskrivningar. Om det finns ett samband mellan  $x$  och  $y$  i populationen ska regressionskoefficienten i populationen, som Teorell och Svensson benämner  $\beta$  (för att helt enkelt

skilja det från b-värdet i vårt urval), vara skilt från noll. Om  $\beta$  är större än noll har vi ett positivt samband och om  $\beta$  är mindre än noll har vi ett negativt samband. Formellt ställer vi därför ofta upp följande hypoteser om sambandet i populationen som vi vill testa på basis av resultaten i vårt stickprov:

$$\begin{aligned}H_0 &: \beta = 0 \\H_{alt} &: \beta \neq 0\end{aligned}$$

Det enklaste sättet att testa dessa hypoteser är att beräkna ett konfidensintervall kring vår urvalskoefficient (b) och se om detta konfidensintervall täcker in 0 eller inte. Om intervallet täcker in 0 kan vi inte förkasta  $H_0$  vilket innebär att vi inte vågar tro på att det samband mellan x och y vi ser i vårt urval verkligen också återfinns i populationen. På metodspråk heter det att regressionskoefficienten är icke-signifikant, vilket innebär att det inte är statistiskt säkerställt att det skiljer sig från 0. Om konfidensintervallet däremot inte täcker in 0 förkastar vi  $H_0$  och vi säger därmed att vi vågar dra slutsatsen att sambandet som vi har funnit i urvalet också gäller i populationen (effekten är så stor att vi håller det för ytterst osannolikt att värdet i populationen verkligen är 0). Vi säger då att regressionskoefficienten är statistiskt signifikant.

Tidigare på kursen har ni sett hur man beräknar konfidensintervall för exempelvis proportioner. Logiken för att beräkna konfidensintervall för b-värden är liknande. Precis som i det förra fallet börjar vi med att beräkna felmarginalen. Felmarginalen för en regressionskoefficient får vi helt enkelt genom att multiplicera regressionskoefficientens standardavvikelse – dess standardfel – med det kritiska värdet för den valda säkerhetsnivån.

$$\text{Felmarginal} = \text{Kritiskt värde} \times \text{Standardfel} \quad (4)$$

Och vad är regressionskoefficientens standardfel för något? Vi kan se det som den standardavvikelse vi skulle förvänta oss om vi drog nya urval från en population och gjorde nya regressioner på dessa.

Precis som i fallet med urvalsproportioner så har vi att väga precision mot säkerhet när vi väljer säkerhetsnivån. När det gällde de valda säkerhetsnivåerna för proportioner så fick vi de kritiska z-värdena för dessa från normalfördelningen. Av anledningar som går utanför den här kursen så bör man dock inte använda sig av normalfördelning när man beräknar felmarginaler för regressionskoefficienter utan av t-fördelningen. Den senare fördelningen är dock väldigt lik normalfördelningen och för n större än 100 är det nästan omöjligt att se skillnad på dem. Givet att vi har bestämt oss för en viss säkerhetsnivå, exempelvis 95 procent, så får vi alltså felmarginalen genom att multiplicera det kritiska t-värdet för denna säkerhetsnivå med b-värdets standardfel.

$$\text{Felmarginal} = t_{kv} * se_b \quad (5)$$

Som alla kan se är logiken densamma som när vi beräknade felmarginaler för proportioner, den enda skillnaden är att vi nu hämtar det kritiska värdet från t-tabellen i stället för från z-tabellen. För att erhålla konfidensintervallet för vårt skattade b-värde subtraherar och adderar vi sedan felmarginalen till vårt b-värde.

$$\text{Konfidensintervall} = b \pm \text{Felmarginalen} = b \pm t_{kv} * se_b \quad (6)$$

Om detta konfidensintervall täcker in 0 så törs vi inte dra slutsatsen att det finns ett samband i populationen, men om det inte täcker in 0 så törs vi dra slutsatsen att ett samband finns. Vi kan alltid testa om det finns ett samband i populationen på detta sätt. Samtidigt är det dock lite omständligt att beräkna konfidensintervallet varje gång man vill testa om det finns ett signifikant samband. Lyckligtvis finns det dock ett enklare sätt. Om det t-värde som vi (oftast via datorn) erhåller för b-värdet ligger utanför det kritiska intervall som t-värdestabellen ger oss kommer konfidensintervallet inte att täcka in 0.

Låt oss exempelvis anta att vi har ett urval om 2000 personer. Det kritiska t-värdet för 95 procents säkerhetsnivå är då – precis som i fallet med proportioner – 1,96. Anta att datorn anger att t-värdet för en viss variabel är 2,04. Vi drar då slutsatsen att det finns ett samband i populationen (vi förkastar  $H_0$ ) då t-värdet faller utanför det kritiska intervallet som avgränsas av -1,96 och +1,96. Om variabelns t-värde däremot hade varit större än -1,96 men mindre än +1,96 hade vi inte vågat dra slutsatsen att det verkligen finns ett samband i populationen.

Låt oss ännu en gång använda oss av våra tre fingerade exempel från förra föreläsningen.

1. När vi genomför den bivariata regressionsanalysen erhåller vi följande värden:  $b = 0,48$ ,  $se_b = 0,16$ ,  $t = 3(0,48/0,16)$ . Det kritiska t-värdet på 95 procents säkerhetsnivå är här 1,96 (då  $n = 2000$ ). Vi finner därmed att vi kan förkasta nollhypotesen att det inte finns något samband i populationen då t-värdet (3) ligger utanför det kritiska intervallet (3 är större än +1,96). Om vi skulle skatta ett konfidensintervall runt koefficienten skulle det sträcka sig från 0,17 ( $0,48 - 1,96 \times 0,16$ ) till 0,79 ( $0,48 + 1,96 \times 0,16$ ). Effekten av ideologisk placering på inställningen till behovet av ökad jämställdhet mellan könen är således statistisk signifikant på 95 procents säkerhetsnivå.
2. När vi genomför den bivariata regressionsanalysen erhåller vi följande värden:  $b = 0,25$ ,  $se_b = 0,11$ ,  $t = 2,27(0,25/0,11)$ . Det kritiska t-värdet på 95 procents säkerhetsnivå är här 1,96 (då  $n = 2000$ ). Vi

finner därmed att vi kan förkasta nollhypotesen att det inte finns något samband i populationen då t-värdet (2,27) ligger utanför det kritiska intervallet (2,27 är större än +1,96). Effekten av utbildning på inställningen till EU är således statistisk signifikant på 95 procents säkerhetsnivå. Om vi ökar säkerhetsnivån till 99 procent finner vi dock att effekten inte är statistiskt signifikant (kritiskt t-värde är nu 2,58) då 2,27 är mindre än 2,58.

3. När vi genomför den bivariata regressionsanalysen erhåller vi följande värden:  $b = -1,15$ ,  $se_b = 0,98$ ,  $t = -1,17(-1,15/0,98)$ . Det kritiska t-värdet på 95 procents säkerhetsnivå är här 2,00 (då  $n = 60$ ). Vi finner därmed att vi inte kan förkasta nollhypotesen att det inte finns något samband i populationen då tvärdet (-1,17) ligger inom det kritiska intervallet (-1,17 är större än -2 men mindre än 2). Effekten av regeringssätt på korrupsionsgraden är således inte statistisk signifikant.

## 2.1 Signifikanstest vid totalundersökningar?

När vi gör beskrivningar är vi ofta genuint intresserade av en existerande population, men så är sällan fallet med en förklaring. Förklaringar handlar nästan uteslutande om mer generella samband mellan variabler, sådana att en ökning av  $x$  predicerar en förändring i  $y$ . Inte bara i de fall vi känner till – utan även i framtida fall som snart kommer att ske eller i den teoretiska superpopulation som genererar de verkliga fall vi kan studera. Därför är det svårt att tänka sig en totalundersökning när man håller på med förklaringar. Av samma anledning gör vi nästan alltid signifikanstest när vi genomför regressionsanalyser.

Även om vi har studerat alla revolutioner som ägt rum, är det förmodligen revolutioner som fenomen snarare än populationen av inträffade revolutioner vi är intresserade av. Det här kan man uttrycka på lite olika sätt. I samlingslitteraturen pratar man om superpopulationer. Vi kan då tänka oss en superpopulation av alla revolutioner som någonsin kommer att inträffa och betrakta de revolutioner som hittills skett som en dragning ur denna population. Inom andra traditioner pratar man i stället om en datagenererande process (DGP), vilket är en underliggande statistisk modell vars dynamik och kausala samband ger upphov till den värld vi observerar. Detta är ett vanligt uttryckssätt när vi har en följd av observationer över tid, eftersom det är svårt att tänka sig dem som dragna ur en population. Teorell och Svensson (s. 215–218) beskriver detta i termer av epistemologisk probabilism. På grund av de mätfel vi gör, och alla de mikrosamband vi inte kan observera men som tillsammans skapar vår komplexa värld, kan vi betrakta den verklighet vi observerar som åtminstone delvis genererad av slumpprocesser. Samma typ av resonemang kan förövrigt förklara varför normalfördelningar är så vanliga.



Ett annat sätt att motivera detta, åtminstone i fallet med signifikanstest av regressionskoefficienter, är som en naturlig referenspunkt för vad som utgör ett starkt samband. Ett insignifikant samband är då ett samband som inte är starkare än att det mycket väl skulle kunnat ha genererats av en slumpprocess. Vi behöver alltså inte anta att våra observationer av verkligheten är (delvis) genererade av slumpprocesser, för att använda dessa som referenspunkt.

## 2.2 Sammanfattning

Låt oss nu summera avsnittet om hur vi kan avgöra om sambandet är signifikant. Notera att alla metoder ger samma slutsatser. För er är de två första metoderna viktigast. Senare i livet kommer ni mest att använda de två sista metoderna.

- T-värdet är högre än det kritiska t-värdet.
- Regressionskoefficienten är mer än  $t_{kv}$  gånger så stor som koefficientens standardfel. Givet approximationen  $t_{kv} = 2$ , är det samma sak som att koefficienten är minst dubbelt så stor som dess standardfel.
- Konfidensintervallet runt koefficienten omsluter inte värdet 0.
- Det står asterisker efter regressionskoefficienten. Läs under tabellen för att se vilken säkerhetsnivå de motsvarar. Det är den vanligaste metoden när man läser en regressionstabell.
- P-värdet är mindre än risknivån ( $risk = 1 - säkerhetsnivå$ ). Det är den vanligaste metoden när man tolkar output från ett statistikprogram.

## 3 Att läsa en regressionstabell

Även om det är fullt möjligt att utföra enklare regressionsanalyser med en simpel miniräknare – vilket man ofta får göra på fortsättningskurser i statistik – beräknar vi sällan regressionsresultaten manuellt. Det vanliga är att vi läser en regressionstabell som andra sammanställt eller att vi läser av den output vi erhåller från vårt statistikprogram. Då är det viktigt att vi vet var vi hittar de värden vi letar efter och vad de kallas.

Regressionstabeller brukar struktureras så att resultaten från regressionsmodellerna anges kolumnvis, så att den första kolumnen motsvarar den första modellen, den andra kolumnen den andra modellen, och så vidare. Varje variabel har en egen rad där dess regressionskoefficient redovisas. Under koefficienterna hittar vi oftast koefficientens standardfel inom parenteser, men det kan också vara t-värdet. Oavsett vilket bör det framgå vad som anges i en not under tabellen.

	(1)	(2)
Choklad	2,81*** (0,50)	2,28*** (0,64)
BNP/cap		0,20 (0,16)
Konstant	-3,99 (3,00)	-8,42* (4,58)
Observationer	23	23
Standardfel	6,60	6,51
$R^2$	0,60	0,63

Standardfel i parenteser.

\*  $p < 0.10$ , \*\*  $p < 0.05$ , \*\*\*  $p < 0.01$

Tabell 1: Chokladkonsumtion och Nobelpris

I regel visas vilka regressionskoefficienter som är statistiskt signifikanta med asterisker (\*). Olika antal asterisker motsvarar då olika säkerhetsnivåer. Det vanligaste är \* = 90 procent, \*\* = 95 procent och \*\*\* = 99 procent, men detta bör alltid anges i en not under regressionstabellen. Eftersom vi vill att ni ska kunna tolka statistisk signifikans utan hjälp av asterisker kommer ni inte att se dem så mycket under kursen.

Tabell 3 redovisar resultaten från två regressioner av antalet Nobelpristagare. Den första kolumnen redovisar resultaten från en bivariat regression med endast chokladkonsumtion (kg per invånare och år) som förklarande variabel. I den andra kolumnen har även BNP per capita (tusentals dollar) inkluderats, vilket ger oss en trivariat regression.

## 4 Multivariat regression

Under den förra föreläsningen diskuterades hur man belägger samband mellan två variabler med hjälp av bivariat regressionsanalys. Under dagens föreläsning ska vi titta närmre på hur regressionsanalys kan användas i de fall då vi har fler än en förklaringsfaktor (oberoende variabel). På metodjargong säger vi att vi går från bivariat till multivariat regressionsanalys.

Något förenklat kan man säga att det finns tre huvudsakliga skäl att gå från bivariat till multivariat analys. Vi kan lyfta in ytterligare oberoende variabler i analysen i syfte att:

- Förbättra förklaringen.
- Isolera sambandet.
- Hitta orsaksmekanism.

Den första anledningen är kanske den mest intuitiva. Få av oss tror på allvar att samhällsvetenskapliga fenomen som krig, demokrati eller inställningen till jämställdhet har en enda förklaring. Ofta tänker vi oss i stället att inställning till jämställdhet kan förklaras av flera faktorer: utbildningsnivå, kön, ålder, politisk ideologi, osv. Med andra ord, om vi på ett tillfredsställande sätt ska kunna förklara variation i inställning till jämställdhet inom en befolkning så måste vi tillåta mer än en oberoende variabel i förklaringsmodellen. Ett sätt att göra detta är genom att skatta en multivariat regressionsmodell. De övriga två anledningarna kräver dock lite mer ingående förklaring. Men innan vi tar oss an frågorna om hur vi med hjälp av multivariat regression kan isolera samband respektive hitta orsaksmekanismer så ska vi backa bandet en aning, till den föregående föreläsningen och den bivariata regressionsanalysen. En fråga lämnades nämligen obesvarad där, nämligen den om våra generaliseringsmöjligheter.

\* \* \*

Givet att vi funnit en (bivariat) kontrafaktisk skillnad och även kan ge argument för den antagna orsaksriktningen blir nästa steg att försöka isolera vårt samband från alternativa variabler som potentiellt kan förklara värdet på såväl vår oberoende som beroende variabel. En kollega vid institutionen (Pär Zetterberg) fann i en regressionsanalys ett bivariat samband mellan en viss typ av könskvoteringslagstiftning till parlament och kvinnliga medborgares politiska intresse. Vi bör då fundera över variabler som föregår både kvoteringslagstiftningen och politiskt intresse i tid och som potentiellt kan förklara utfallen på båda dessa variabler. En sådan variabel skulle kunna vara socioekonomisk utveckling. Risken finns nämligen att det bivariata sambandet är skenbart, eller spuriöst för att använda en mer teknisk term. Det vill säga vi tror att införandet av kvotering ökar kvinnliga medborgares politiska intresse när det i själva verket är så att socioekonomisk utveckling ökar sannolikheten att ett land inför kvotering och ökar benägenheten för kvinnliga medborgare i landet att intressera sig för politik (tack vare ökad utbildningsnivå, osv.).

Om sambandet mellan kvotering och kvinnors politiska intresse skulle minska i styrka och ej längre vara signifikant när vi kontrollerar för socioekonomisk utveckling, då konstaterar vi med andra ord att det bivariata sambandet var spuriöst och alltså icke-kausalt. Om sambandet dock fortfarande är signifikant, då har vi kunnat isolera för socioekonomisk utveckling och vi har i viss mån fått stöd för isoleringskriteriet. Observera dock att det givetvis potentiellt sett finns åtskilliga andra variabler som kan påverka såväl kvoteringslagstiftning som kvinnors politiska intresse. Det är därför viktigt att komma ihåg att vi inte kan kontrollera för allt. Detta är också en av anledningarna till varför teorier är så nyttiga i denna typ av undersökningar. Teorier hjälper oss att identifiera den grupp av bakomliggande variabler som är viktigast att kontrollera för.

Givet att vi har fått visst stöd för isoleringskriteriet kan vi även diskutera det fjärde orsakskriteriet: att belägga orsaksmekanismer. För att kunna leverera en orsaksförklaring menar Teorell och Svensson att vi behöver någon typ av argument för orsaksmekanismen, dvs varför orsak leder till verkan. Eller i ovanstående fall: varför kvoteringslagstiftning leder till ökat politiskt intresse bland kvinnor. Om vi ska tro teorier om genus och politisk representation skulle en sådan mekanism kunna vara att kvotering ökar andelen kvinnor i parlamentet, som kan vara politiska förebilder åt kvinnliga medborgare. På teoretiska grunder tror vi alltså både att kvotering verkligen implementeras effektivt och ökar andelen kvinnor i parlamentet och att dessa kvinnor kan vara politiska förebilder och därmed ökar kvinnors intresse för politik. Till skillnad från när vi försöker isolera ett samband så behöver inte ett försvagat och icke-signifikant samband i trivariat analys innebära att sambandet mellan kvotering och kvinnors politiska intresse är icke-kausalt. Om vi finner ett positivt samband mellan kvotering och andelen kvinnor i parlament och dessutom ett positivt samband mellan andelen kvinnor i parlament och kvinnors politiska intresse, då har vi i stället identifierat den mekanism varigenom effekten mellan kvotering och kvinnors politiska intresse går. Sambandet mellan kvotering och kvinnors politiska intresse är därmed indirekt och i allra högsta grad kausalt.

Det är viktigt att skilja mellan spuriösa och indirekta samband. För medan de förra är icke-kausala är de senare kausala. Att reda ut skillnaden mellan dessa olika samband kommer vi att ägna det mesta av den tid som återstår av denna föreläsning. Ni kommer också att få öva på detta inför seminarium 3 och 4. Här följer dock en kort sammanfattning, som ni kan ha med er framöver. Kontrollvariabeln benämns här  $Z$ , men på andra ställen används  $x_2$ .

- Om bivariat effekt av  $X$  kvarstår vid kontroll för  $Z$ , och  $Z$  är bakomliggande (dvs föregår både  $X$  och  $Y$  i tid) så har vi isolerat sambandet mellan  $X$  och  $Y$ . Hypotesen får stöd.
- Om bivariat effekt av  $X$  försvinner vid kontroll för  $Z$ , och  $Z$  är bakomliggande (dvs föregår både  $X$  och  $Y$  i tid) så var ursprungligt samband ett skensamband och spuriöst. Hypotesen får ej stöd.
- Om bivariat effekt av  $X$  försvinner vid kontroll för  $Z$ , och  $Z$  är mellanliggande (dvs ligger mellan  $X$  och  $Y$  i tid) så var ursprungligt samband indirekt. Vi har specificerat en orsaksmekanism. Hypotesen får stöd.

#### 4.1 Den multivariata regressionsekvationen

Innan vi går in närmare in på multivariat regression i syfte att isolera samband respektive identifiera en orsaksmekanism så vill jag kort gå igenom den

multivariata regressionsmodellen. Logiken för multivariat regression är densamma som för bivariat regression. Beräkningarna är dock mer komplicerade eftersom vi nu ska anpassa ett plan i stället för en linje till observationerna. Lyckligtvis behöver vi inte oroa oss för denna komplikation då datorerna sköter all räkning åt oss. Vi ska i stället uppehålla oss vid de substantiella tolkningarna av regressionsresultaten.

Utan att gå in närmare i detalj på den multivariata regressionsekvationen ska jag dock först säga några ord om den. Teorell och Svensson går på s. 191 igenom den multivariata regressionsekvationen, som på många sätt påminner om den bivariata regressionsekvationen. I det fall när vi har två oberoende variabler kommer regressionsekvationen att ta formen av ett tvådimensionellt plan och kan skrivas (ett nedsänkt "i" ska egentligen finnas efter "y", "x" och "e", för att symbolisera respektive analysenhet; se s. 191):

$$y = a + b_1x_1 + b_2x_2 + e \quad (7)$$

Trots något mer komplicerade matematiska beräkningar för att beräkna intercept och regressionskoefficient så är logiken densamma som i bivariat analys. Vi använder minsta kvadratmetoden för att hitta det regressionsplan som minimerar summan av de kvadrerade avvikelserna. Tolkningen påminner också mycket om det bivariata fallet:  $a$  är det förväntade värdet på  $y$  när de oberoende variablerna antar värdet 0. Och regressionskoefficienten  $b_1$  ger den genomsnittliga förändringen i  $y$  då  $x_1$  ökas med en enhet och  $x_2$  hålls konstant vid ett visst värde, medan  $b_2$  ger den genomsnittliga förändringen i  $y$  då  $x_2$  ökas med en enhet och  $x_1$  hålls konstant vid ett visst värde (alternativt "kontrollerar för  $x_1$ ", "isolerar för  $x_1$ ", "filtrerar bort effekten av  $x_1$ ").

## 4.2 Isolera samband

Som jag nämnt tidigare kan vi inte kontrollera för alla tänkbara variabler. Annorlunda uttryckt är det fundamentala orsakssambandet i grunden olösligt: Vi kan inte uttala oss tvärsäkert om orsakssambandet mellan  $x$  och  $y$ . I stället är vi hänvisade till att argumentera för ett sådant orsakssamband med hjälp av de fyra orsakskriterierna. Som ni förhoppningsvis vet vid det här laget säger ett av dessa kriterier att vi bör sträva efter att isolera effekten av vår oberoende variabel från andra bakomliggande förklaringar som kan tänkas förklara såväl  $x$  som  $y$ . Nu ska vi mer i detalj gå in på hur man gör detta med hjälp av multivariat regressionsanalys.

Till vår hjälp tar vi de exempel som belystes i samband med föreläsningen om bivariat regressionsanalys:

1. Sambandet mellan placering på vänster-höger-skalan och inställning till jämställdhet.
2. Sambandet mellan utbildning och inställning till EU.

	(1)	(2)
Vänster–höger	0,48 (3,00)	0,03 (0,78)
Kön		1,78 (3,18)
Konstant	2,97	5,14
Observationer	2000	2000

t-värden i parenteser.

Tabell 2: Inställning till jämställdhet

### 3. Sambandet mellan regeringssätt och korruption.

#### 4.2.1 Exempel 1

Som ni kanske minns så lyckades vi under den förra föreläsningen belägga ett bivariat samband mellan placering på vänster–höger-skalan (0=långt till höger och 10=långt till vänster) och inställningen till behovet av ökad jämställdhet mellan könen (0=litet behov och 10=stort behov). Enligt resultaten från den bivariata regressionsanalysen så medför en enhets ökning på vänster–höger-skalan (ett steg till vänster) att man i genomsnitt blir 0,48 enheter mer positivt inställd till ökat behov av jämställdhet ( $b=0,48$ ). Detta samband visade sig även vara statistiskt signifikant på 95 procents säkerhetsnivå då t-värdet (3) låg utanför det kritiska intervallet (-1,96 till + 1,96).

Genom den bivariata analysen har vi alltså lyckats belägga ett kontrafaktiskt samband mellan ideologisk position och inställningen till jämställdhet. Givet att ideologi är en ganska trögörslig värdering tycks det också rimligt att anta att ideologisk position kommer före inställningen till jämställdhet i tid och således kan vi också argumentera för orsaksriktning. Vi har dock inte isolerat detta bivariata samband för någon annan bakomliggande variabel. Risken finns därför att det bivariata sambandet är spuriöst, alltså skenbart. En bakomliggande variabel som kan tänkas vara viktig att kontrollera för här är uppenbarligen kön. Kanske är det så att en individs kön både påverkar var individen placerar sig ideologiskt och dennes inställning till jämställdhet.

För att se om detta är fallet så kan vi skatta en multivariat regressionsmodell där vi har inställning till behovet av ökad jämställdhet mellan könen som beroende variabel (0–10) och placering på vänster–högerskalan (0–10) och kön (0=man och 1=kvinnor) som oberoende variabler. Algebraisk kan vi skriva detta som:

$$\text{Jämställdhet} = a + b_1 \times \text{VH} + b_2 \times \text{Kön} + e \quad (8)$$

Vad säger då oss dessa resultat? Om vi börjar med b-värdena – de partiella

	(1)
Kön	1,27 (2,94)
Konstant	4,14
Observationer	2000

t-värden i parenteser.

Tabell 3: Placering på vänster–höger-skalan


regressionskoefficienterna – så ser vi att en enhets ökning på vänster–höger-skalan i genomsnitt leder till en ökning i inställningen till jämställdhet med 0,03 enheter när variabeln kön hålls konstant. Som synes är denna effekt mycket mindre än den bivariata effekten (0,48) och av t-värdet kan vi utläsa att effekten nu ej längre är statistisk signifikant på 95 procents säkerhetsnivå, då 0,78 ligger inom intervallet för de kritiska värdena (-1,96 och +1,96). Vi vågar således inte längre förkasta nollhypotesen att ideologisk position inte har någon direkt effekt på inställningen till jämställdhet.

Om vi däremot flyttar vårt intresser från V–H-variabeln till variabeln kön så ser vi att kvinnor i genomsnitt är 1,78 enheter mer positiva till jämställdhet än vad män är, när vi håller ideologisk placering konstant. Eller annorlunda uttryckt, en enhets ökning på variabeln kön – skillnaden mellan man och kvinna – leder i genomsnitt till en ökning i inställningen till jämställdhet med 1,78 enheter när ideologisk position hålls konstant. Som kan utläsas av t-värdet är effekten av kön statistiskt signifikant då t-värdet (3,18) ligger utanför det kritiska intervallet på 95 procents säkerhetsnivå.

När vi kontrollerar för kön så försvinner således merparten av den direkta effekten av ideologisk placering på inställningen till jämställdhet. Detta betyder att det måste finnas ett samband mellan kön och ideologisk position. För om det inte hade funnits ett samband mellan dessa båda variabler så hade den bivariata effekten av V–H kvarstått oförändrad vid kontroll för kön. Ett sätt att ta reda på hur detta samband ser ut är att köra en bivariat regression med ideologisk placering som beroende variabel och kön som oberoende variabel. Resultaten från denna analys presenteras i Tabell 4.2.1.

Som framgår av tabellen så finns det ett positivt samband mellan kön och ideologisk position; i genomsnitt står kvinnorna politiskt till vänster om männen. Eller mer exakt: i genomsnitt befinner sig kvinnorna 1,27 enheter till vänster om männen politiskt. Som framgår av t-värdet är denna effekt också statistiskt signifikant på 95 procents säkerhetsnivå.

Vilken är då den substantiella tolkningen av ovanstående analys? Svaret är att den bivariata effekten av ideologisk placering på inställningen till jämställdhet var spuriös (icke-kausalt), vi lurades alltså att tro att individer som stod till vänster var mer positiva till ökad jämställdhet när det egentligen



Figur 1: Attityder till jämställdhet

berodde på att kvinnor både är mer positiva till jämställdhet och står längre till vänster än männen politiskt. Politisk uppfattning har alltså ingen kausal effekt på inställningen till jämställdhet! Den slutsatsen följer av att kön föregår såväl ideologisk placering som inställningen till jämställdhet i tid. Den bivariata effekten av ideologisk placering kan alltså inte gå via kön då kön nödvändigtvis kommer före ideologisk placering i tid. Detta resonemang redovisas enklast i ett kausaldiagram som det i Figur 4.2.1, där asterisken indikerar att effekten är statistiskt signifikant på 95 procents säkerhetsnivå.

Avslutningsvis kan vi här säga några ord om hur man räknar ut förväntat värde för multivariata regressionsekvationer. Anta att ni blir tillfrågade om vilken inställning till jämställdhet ni tror att en kvinna med ideologisk placering 5 har. Er bästa gissning är då att använda er av de skattade  $a$  och  $b$ -värdena i tabellen ovan. Det svar ni ger är då 7,07 (då  $5,14 + 0,03 \times 5 + 1,78 \times 1 = 7,07$ ). Trots att effekten av ideologisk placering visade sig vara icke-signifikant är det bäst att ta med det värdet i uträkning. För detta värde är vår bästa gissning. Om man trots allt skulle bestämma sig för att utesluta vänster-höger-placering ur uträkningen så måste man göra om analysen, då storleken på effekten av kön på inställningen till jämställdhet kommer att bero på huruvida man kontrollerar för ideologisk placering eller inte.

$$\hat{y} = a + b_1x_1 + b_2x_2$$

$$\text{Jämställdhet} = 5,14 + 0,03 \times 5 + 1,78 \times 1 = 7,07 \quad (9)$$

#### 4.2.2 Exempel 2


När vi utförde bivariat regressionanalys fann vi även ett signifikant positivt samband mellan utbildning och inställningen till EU, det vill säga att högt utbildade tenderade i genomsnitt att vara mer positiva till EU ( $b=0,25$ ) än lågutbildade. Även här tycks orsaksriktningen vara relativt oproblematis. Däremot borde även detta samband isoleras för tänkbara alternativa förklaringar till individers inställning till EU. Precis som kön förklarade både



	(1)	(2)
Utbildning	0,25 (2,27)	0,24 (2,28)
Kön		-0,85 (-2,25)
Konstant	2,02	2,14
Observationer	2000	2000

t-värden i parenteser.

Tabell 4: Inställning till EU



Figur 2: Inställning till EU

ideologisk placering och inställningen till jämställdhet så skulle kön kunna påverka såväl individens utbildningsval som dess inställning till EU. För att kontrollera om det är fallet så skattar vi nu en multivariat regressionsmodell med inställningen till EU (0 till 10) som beroende variabel och kön och utbildning som oberoende variabler. Resultaten för den analysen redovisas i Tabell 4.2.2. Av resultaten framgår att effekten av utbildning kvarstår i stort sett oförändrad när vi kontrollerar för kön. Ett års extra utbildning innebär att individen i genomsnitt blir 0,24 enheter mer positiv till EU när vi kontrollerar för kön. Det framgår också att effekten är statistiskt signifikant på 95 procents säkerhetsnivå då t-värdet (2,28) ligger utanför det kritiska intervallet. Vad gäller kön ser vi dock att kön har en effekt på inställningen till EU. I genomsnitt är kvinnorna 0,85 enheter mindre positiva till EU jämfört med männen. Även denna effekt är statistiskt signifikant på 95 procents säkerhetsnivå.

Resultaten av denna analys redovisas i kausaldiagrammet i Figur 4.2.2. Notera att vi enkelt skulle kunna ersätta frågetecknet i diagrammet med ett b-värde genom att köra en bivariat regression med utbildning som beroende variabel och kön som oberoende variabel.

	(1)	(2)
Presidentialism	-1,15 (0,98)	-1,89 (0,72)
Brittisk koloni		-1,10 (-0,43)
Konstant	7,18	
Observationer	60	60

Standardfel i parenteser.


Tabell 5: Korruption

### 4.2.3 Exempel 3

Den bivariata regressionsanalysen visade även på ett svagt samband mellan regeringssätt och korruption, i riktningen att korruptionen tycktes vara något lägre i presidentiella system än i parlamentariska system. Vid närmare kontroll visade sig dock detta samband vara icke-signifikant – vi kunde inte utesluta möjligheten att det inte finns något samband i populationen. En viktig insikt är dock att precis som samband kan försvinna när vi kontrollerar för bakomliggande variabler så kan de också dyka upp. För att illustrera detta kan vi tänka oss att vi vill kontrollera sambandet mellan regeringssätt (parlamentarism el. presidentialism) och korruptionsgrad för huruvida man har brittisk kolonial bakgrund eller inte. Då det ofta argumenteras för att britterna lämnade efter sig olika administrativa institutioner som motverkar korruption.

Resultaten från en multivariat regressionsanalys med kolonial bakgrund (0=icke-brittisk bakgrund och 1=brittisk bakgrund) presenteras i Tabell 4.2.3. Som vi kan se av tabellen är den negativa effekten av regeringssätt nu större än den var i den bivariata analysen. Den genomsnittliga skillnaden i korruptionsgrad mellan parlamentariska och presidentiella system är i genomsnitt 1,89 enheter när vi kontrollerar för kolonial bakgrund. Denna effekt är nu också statistiskt signifikant på 95 procents säkerhetsnivå då regressionskoefficienten (1,89) är mer än dubbelt så stor som dess standardfel (0,72). Det kritiska t-värdet i detta fall är 2,00, så ”dubbelt så stor” är inte ens en approximation.

Så hur kan de komma sig att effekten av regeringssätt nu är signifikant? Anledningen till det är att brittisk bakgrund har en negativ effekt på såväl förekomsten av korruption som förekomsten av presidentialism. Genom att inte inkludera kolonial bakgrund i analysen underskattade vi därmed effekten av regeringssätt. Den låga korruptionen i många parlamentariska system förklaras alltså inte av att de är parlamentariska utan av att de har en brittisk bakgrund och därmed andra institutioner som motverkar korruption.



Figur 3: Korruption

Detta inser vi först när vi kontrollerar för den koloniala bakgrunden för då kan vi separera effekten av regeringssätt från effekten av de faktorer som har att göra med den koloniala bakgrunden.

### 4.3 Hitta orsaksmekanism

Givet att vi har belagt kontrafaktiskt samband, orsaksriktning och kontrollerat för de viktigaste bakomliggande variablerna så tycks det ganska sannolikt att vi har att göra med ett orsakssamband. För att göra detta ännu mer troligt kan det dock ofta också vara bra att kunna klarlägga den orsaksmekanism varigenom  $x$  leder till  $y$ . Ett sätt att göra detta är helt enkelt att argumentera för en orsaksmekanism på teoretiska grunder. Detta är ofta tillräckligt. De flesta skulle dock hålla med om att orsakssambandet blir ännu mer troligt om vi också kan belägga orsaksmekanismen empiriskt. Ett sätt att göra detta är genom att föra in tänkbara mellanliggande variabler i regressionsanalysen. Vi ska nu exemplifiera detta tillvägagångssätt.

#### 4.3.1 Exempel 1


Ovan fann vi att det finns ett bivariat samband mellan kön och placering på vänster–höger-skalan. Då det inte finns några andra variabler som kan vara bakomliggande till kön är det viktiga inte här att isolera detta samband utan snarare att fundera över varför kvinnor står till vänster om männen politisk; vilken är orsaksmekanismen mellan kön och ideologi? En tänkbar mekanism skulle kunna vara inkomst. Kanske kan det vara så att kvinnor står längre till vänster för att de tjänar mindre. Inkomst skulle då vara en mellanliggande variabel mellan kön och ideologisk position.

För att testa denna hypotes kan vi skatta en multivariat regressionsekvation där placering på vänster–höger-skalan är beroende variabel och kön och inkomst – mätt som månadslön uttryckt i 1000-tals kronor (ett skalsteg motsvarar 1000 kr) – är oberoende variabler. Resultaten av denna analys redovisas i Tabell 4.3.1. Som resultaten i tabellen visar så försvinner den

	(1)	(2)
Kön	1,27 (2,94)	-0,05 (-0,83)
Inkomst		-0,23 (-4,27)
Konstant	4,14	8,14
Observationer	2000	2000

t-värden i parenteser.

Tabell 6: Placering på vänster-höger-skalan



Figur 4: Placering på vänster-höger-skalan

direkta effekten av kön på ideologisk placering nästan helt när vi kontrollerar för inkomst. Givet resultaten så befinner sig kvinnor faktiskt i genomsnitt 0,05 enheter längre till höger än männen när vi kontrollerar för inkomst. Som framgår av t-värdet är dock effekten inte statistiskt signifikant. Inkomst har dock en signifikant direkt effekt på ideologisk placering.

Kom ihåg att de kritiska värdena är högre när vi har få analysenheter, som redovisades under föregående föreläsning baserar sig dessa resultat på ett urval om 60 länder.

Varje enhets ökning av inkomsten – alltså varje extra tusenlapp i månadslön – gör att man i genomsnitt förflyttar sig 0,23 steg till höger politiskt, när vi håller variabeln kön konstant.

Så hur ska vi tolka detta? Var den bivariata effekten av kön på ideologisk placering spuriös? Nej, det är den inte. Effekten är indirekt och går via inkomst – kvinnor står längre till vänster än männen därför att de tjänar mindre. Vi har därmed specificerat en orsaksmekanism (inkomst) till sambandet mellan kön och ideologi. Anledningen att tolkningen blir att effekten av kön är indirekt och inte spuriös är att kön kommer före inkomst i tid. Kausalpilen måste gå från kön till inkomst, såsom visas i kausaldiagrammet i Figur 4.3.1.

Det centrala här är att inse den viktiga skillnaden mellan spuriösa och indirekta samband. Ett spuriöst samband innebär att det inte finns någon

kausalt effekt mellan oberoende och beroende variabel, vilket det däremot finns om effekten av en variabel är indirekt. Även om kön inte har någon direkt effekt på ideologisk uppfattning så spelar kön roll för var olika individer står politiskt. Det faktum att man är kvinna gör att man står längre till vänster politiskt och en av anledningarna att man gör det är att kvinnor tjänar mindre än män.

Effekten av kön på inkomst i diagrammet (-5,74) kan vi erhålla på två olika sätt. Antingen kan vi köra en bivariat regression med inkomst som beroende variabel och kön som oberoende variabel eller så kan vi erhålla b-värdet på matematisk väg. Även om det senare sättet är lite överkurs – och därför ingenting som kommer på tentan – kan någon ändå vilja veta hur man gör detta. Den som inte räds lite ekvationslösning kan därför läsa nästa stycke medan övriga kan hoppa till exempel 2.

Utgångspunkten är att systemet är slutet. Givet att kön är en bakomliggande variabel kan den bivariata effekten av kön på vänster–höger-skalan (1,27) bara ta två vägar. Antingen går den direkt till ideologisk position eller så går den via inkomst – den totala effekten (den bivariata effekten) är här summan av den direkta effekten (-0,05) och den indirekta effekten. För att erhålla den indirekta effekten multiplicerar vi b-värdet för kön på inkomst (vilket här är okänt) med inkomstvariabelns direkta effekt (-0,23). Vi får då en ekvation med en okänd att lösa ut:

$$\begin{aligned} \text{Total effekt} &= \text{Direkt effekt} + \text{Indirekt effekt} \\ 1,27 &= -0,05 + b \times -0,23 \\ 1,32 &= b \times -0,23 \\ b &= -5,74 \end{aligned} \tag{10}$$

Vi finner således att den direkta effekten av kön på inkomst är -5,74. I genomsnitt tjänar kvinnor således 5 740 kronor mindre än männen i månaden (observera att detta exempel är fingerat så även om det finns en skillnad i lön mellan män och kvinnor är den inte fullt så här stor). Ett lättare sätt att erhålla detta värde hade dock varit att köra en bivariat regression med inkomst som beroende och kön som oberoende variabel. Vilket hade gett samma resultat.

### 4.3.2 Exempel 2

Ovan fann vi att sambandet mellan utbildning och inställning till EU kvarstår även vid kontroll för den bakomliggande variabeln kön. Det kan därför nu vara intressant att fundera över vad det är som gör att högutbildade är mer positiva till EU än vad lågutbildade är. Två tänkbara mekanismer skulle kunna vara att högutbildade är mer positiva till EU för att de tjänar mer eller för att de står längre till höger politiskt. Det tycks rimligt att anta att

	(1)	(2)	(3)
Utbildning	0,25 (0,11)	0,20 (0,10)	0,08 (0,09)
Inkomst		0,11 (0,06)	
Vänster–höger			–1,14 (–0,27)
Konstant	2,02	2,14	8,14
Observationer	2000	2000	2000

Standardfel i parenteser.


Tabell 7: Inställning till EU

både inkomst – mätt som månadslön uttryckt i 1000-tals kronor (ett skalsteg motsvarar 1000 kr) – och politisk placering kommer efter utbildningsnivå i tid varför både dessa variabler i detta fall är mellanliggande och inte bakomliggande variabler.

För att testa dessa båda mekanismer utför vi två multivariata regressionsanalyser. En med inställning till EU som beroende och utbildning och inkomst som oberoende variabler. Och en med inställning till EU som beroende och utbildning och ideologisk placering som oberoende variabler. Resultaten från den första av dessa analyser redovisas i Tabell 4.3.2.

Som framgår av tabellen så kvarstår en signifikant direkt effekt av utbildning på inställningen till EU även vid kontroll för inkomst (även om den är något mindre än i den bivariata analysen). Vi ser också att inkomst har en signifikant direkt effekt på inställningen till EU (vid 90 procents säkerhetsnivå). Slutsatsen är således att såväl högutbildade som höginkomsttagare är mer positiva till EU. Däremot verkar det inte som om någon större del av utbildningseffekten tar vägen via inkomst. Inkomst är alltså ingen viktig orsaksmekanism för sambandet mellan utbildning och inställningen till EU. Den kausala tolkningen redovisas i Figur 6. Precis som i det tidigare exemplet kan effekten av utbildning på inkomst antingen erhållas från en bivariat analys med inkomst som beroende variabel och utbildning som oberoende variabel eller på algebraisk väg genom att utgå från den bivariata effekten av utbildning på inställningen till EU.

I Tabell 4.3.2 redovisas resultaten från analysen med inställningen till EU som beroende och utbildning och ideologisk placering som oberoende variabler. När vi kontrollerar för ideologisk placering försvagas den direkta effekten av utbildning på inställningen till EU avsevärt. Effekten är ej heller statistiskt signifikant (t-värdet ligger inom det kritiska intervallet). Däremot har ideologisk placering en signifikant negativ effekt på inställningen till EU. För varje steg till vänster som man rör sig på vänster–höger-skalan så blir



Figur 5: Inställning till EU

man i genomsnitt 1,14 enheter mer negativ till EU om ens utbildning hålls konstant.

Så innebär då detta att det bivariata sambandet mellan utbildning och inställningen till EU är skenbart (spuriöst)? Nej, inte heller denna gång. Återigen är anledningen att kontrollvariabeln här är mellanliggande och inte bakomliggande. Givet att vi antar att utbildning föregår ideologisk position i tid (vilket tycks rimligt). Anledningen att effekten försvagas är därför att en stor del av effekten av utbildning går via ideologisk position. Anledningen att lågutbildade är mer negativa till EU än högutbildade är att de lågutbildade står längre till vänster politiskt. Ideologisk placering är således en orsaksmekanism till sambandet mellan utbildningsnivå och inställningen till EU. Detta resonemang illustreras grafiskt i Figur 5.

## 5 Att jämföra koefficienter

När man har utfört en multivariat regression av något slag är man ofta frestad att börja jämföra den relativa styrkan hos olika effekter, dvs är variabel A viktigare än variabel B om vi vill förklara variabel C. Hur frestande detta än kan tyckas bör vi vara medvetna om att detta i de flesta fall är ett mycket riskabelt företag. För ofta är våra variabler uttryckta på väldigt olika skalor, vilket innebär att vi i bästa fall ställs inför att jämföra äpplen med päron och i värsta fall inför att jämföra äpplen med patenträtter. De enda fallen när en jämförelse av den relativa styrkan hos olika effekter är möjlig i egentlig mening är när två variabler har en gemensam naturligskala eller två variabler är naturliga dikotomier".

Ett ofta förekommande förslag i den statistiska litteraturen är att vi kan jämföra två effekter om vi standardiserar de oberoende variablerna så att de får en gemensam skala. Vanligtvis transformeras variablerna på ett sådant sätt att de alla får ett medelvärde 0 och standardavvikelsen 1. Om vi då regresserar den standardiserade beroende variabeln på de standardiserade oberoende variabler erhåller vi de standardiserade regressionskoefficienterna.

Nu mera tycks dock de flesta forskare vara överens om att detta sällan löser problemet med att jämföra den relativa styrkan hos olika effekter. Pärön blir inte äpplen bara för att vi standardiserar dem!

## 6 Kombinationsstudier

Det förs ständigt en diskussionen om kvantitativa respektive kvalitativa metoders användningsområden och begränsningar. De flesta är nog överens om att uppdelningen "kvantare" (personer som främst utför extensiva studier) och "kvallare" (personer som främst utför intensiva studier) är olycklig, särskilt som den leder till onödiga positioneringar och begränsar forskarens möjliga angreppssätt. Valet av metod bör styras av forskningsfrågan och luckorna i tidigare forskning, snarare än vilket läger som forskaren tillhör. Och diskussioner om huruvida en typ av metod alltid är bättre än annan är sällan fruktbara.


En mer konstruktiv utgångspunkt är att se intensiva och extensiva studier som komplementära. Både traditionerna har sina respektive styrkor och svagheter. Det är svårt att visa på samvariation och isolera orsakssamband i en intensiv studie, men i gengäld kan det i dessa studier ofta vara enklare att finna belägg för tidsordning och orsaksmekanism. På motsatt vis är extensiva studier bra på samvariation och isolering men brister ofta i att belägga tidsordning och spåra orsaksmekanismer.

*Method of Agreement* innebär att vi väljer fall som har samma (likartade) utfall på den beroende variabeln men är så olika som möjligt i alla andra relevanta avseenden. Notera att vi fortfarande saknar belägg för kontrafaktisk skillnad! Endast i *Method of Difference* har vi belägg för kontrafaktisk skillnad, men de intensiva metodernas akilleshäl kvarstår – vi vet fortfarande inte om sambandet är systematiskt eller slumpartat. Extensiva upplägg är därför bättre på att ge belägg för samvariation eller kontrafaktisk skillnad samt isolera andra förklaringar. De har också fördelen att de kan hantera probabilistiska samband bättre än fåfallsstudier (se Teorell & Svensson s.241).

Hela dagen har vi gjort antaganden om orsaksriktningar, sådana att  $x$  påverkar  $y$  samtidigt som  $y$  inte har någon effekt på  $x$ . Sådana antaganden brukar vara mer problematiskt än vad det har varit i våra exempel. De kvantitativa metoder som finns för att belägga orsaksriktning kräver bra data med tidsvariation sant ofta andra antaganden, exempelvis om effektens fördröjning (hur lång tid det tar för en förändring i  $x$  att resultera i en förändring i  $y$ ). Och även om extensiva studier kan visa på en orsaksmekanism, vilket vi har tittat på idag, kan de inte följa en process lika nära som en intensiv studie kan göra. *Utöver* detta fyller intensiva studier även viktiga teoriutvecklande eller hypotesgenererande funktioner, på ett sätt kvantitativa studier mer sällan gör.

För att dra nytta av de relativa fördelarna i båda traditionerna framhåller





många kombinationsstudier som ett ideal. Utgångspunkten är att den enda möjligheten för att hitta belegg för alla fyra orsakskriterierna är att kombinera extensiva och intensiva ansatser. Det är förstås tidskrävande att genomföra flera olika delstudier, men kom ihåg att allt inte nödvändigtvis måste göras i samma uppsats eller ens av samma forskare. Man kan också utgå från tidigare forskning för att identifiera vilken typ av studier som fältet är i störst behov av. Den vanligaste typen av kombinerade metoder är förmodligen att välja fall på basis av en extensiv studie. Om syftet är att belägga orsaksriktning och/eller orsaksmekanism bör vi välja fall som passar in i huvudmönstret, det vill säga som är representativa för det samband som vi har funnit. Det kallas ibland för att välja ett fall på regressionslinjen. En annan möjlighet är att använda den intensiva studien till att generera nya (konkurrerande eller kompletterande) hypoteser om vad som kan förklara ett visst fenomen. Vi väljer då länder som ligger långt ifrån regressionslinjen och alltså inte kan förklaras av våra nuvarande teorier.

Figur 6 visar återigen sambandet mellan chokladkonsumtion och antalet Nobelpris. Om vi skulle välja ett avvikande fall för att leta nya förklaringar till frekvensen av Nobelpris skulle kanske Sverige vara ett bra val. Sveriges höga antal Nobelpris kan inte förklaras av vår chokladkonsumtion, vilket innebär att det borde finnas en annan variabel som är viktig i det svenska fallet (och därmed kanske även i andra fall). Spelar det möjligtvis någon roll vilket land det är som delar ut prisen? Om vi skulle välja ett illustrativt fall som är representativt för sambandet skulle vi välja något av länderna på regressionslinjen. I detta fall är det förmodligen en god idé att välja Schweiz,

eftersom det är enklare att försöka spåra mekanismen i ett land med hög chokladkonsumtion och många Nobelpristagare. Så är det inte alltid. Ibland är det tvärtom enklare att hitta mekanismer i frånvaron av någonting.

## 7 Några saker att se upp för

Föreläsningen avslutades med fem saker man bör vara vaksam på när man gör en regressionsanalys. Nummer tre och fyra handlar om metoder vi inte lär ut på kursen, men som kan vara ett lagom stort steg att ta för den som använder regressionsanalys i sin C-uppsats och gärna vill lära sig något nytt.

1. Det är svårt att jämföra regressionskoefficienter med varandra. För det första är variabler ofta mätta på helt olika skalor. En variabel som mäter månadsinkomst kanske antar värden från noll till tiotusentals kr. Den kommer nästan alltid ha en väldigt liten regressionskoefficient, eftersom koefficienten mäter effekten av en förändring av inkomsten med en krona per månad. För det andra kan spridningen skilja sig åt mellan variabler, även om skalorna är jämförbara. I många situationer är en stor effekt ointressant, om nästan alla observationer har samma värden. För det tredje är det aldrig okomplicerat att jämföra effekter av vitt skilda saker, även om skalorna och spridningen är jämförbar. Hur relevant är det att jämföra helt olika fenomen med varandra, som exempelvis hur ens inkomst förändras av att byta yrke med inkomsteffekten av att läsa ytterligare ett år på universitetet? Men trots svårigheterna är det ofta önskvärt att jämföra effekter med varandra, antingen i en och samma regressionsmodell eller att jämföra en effekt med liknande studier i tidigare forskning. Det viktiga är att vi är försiktiga och medvetna om problemen.
2. Regressionsanalysen säger ingenting om orsaksriktning. När vi bestämmer vilken variabel som är oberoende och vilken variabel som är beroende, men resultaten från en regressionsanalys berättar inte om vårt antagande var korrekt. Att sambandet i själva verket går åt motsatt håll hindrar inte resultaten från att bli statistiskt signifikanta. Vill vi skaffa belägg för orsaksriktningen bör vi använda sunt förnuft, teori och tidigare forskning eller andra metoder. Såväl intensiva studier som experiment är mer lämpade för att visa i vilken riktning ett samband går.
3. Ofta kommer många observationer från ett och samma fall. Vanligast är kanske när vi har data mellan länder och över tid, så att en observation är Sverige 2012 och en annan observation är Sverige 2013. Den typen av data erbjuder unika möjligheter för våra analyser men den skapar också problem. Å ena sidan kan vi, under vissa antaganden som exempelvis

hur lång tid det tar för en effekt att äga rum, studera vilken variabel som tycks påverka den andra. Vi kan också välja att endast studera variation över tid, exempelvis genom att inkludera en dummyvariabel per land (eller vad vi nu studerar). På så vis kan vi kontrollera för alla de faktorer som är stabila över tid och som vi inte kan observera. Å andra sidan innebär den typen av data att vi lätt överdriver den statistiska signifikansen i våra resultat. Om vi inte tar hänsyn till att Sverige 2011 och Sverige 2012 knappast är oberoende av varandra, kommer vi få resultat som ser ut att vara mer signifikanta än vad de egentligen är.

4. Är den beroende variabeln dikotom? Vanlig linjär regression är dåligt lämpad för variabler som bara kan anta två värden. Ett av skälen till det är att den kan ge upphov till orimliga prediktioner. Även om den beroende variabel bara kan anta värdena 0 och 1, så kan den linjära regressionsmodellen göra prediktioner som är lägre än 0 och högre än 1. Det vanligaste sättet att hantera dikotoma beroende variabler är genom logistisk regression.
5. Det är svårt att isolera för alla tänkbara förklaringar. Vi vet sällan vilka alla möjliga bakomliggande förklaringar är. Och även om vi visste det, är det inte självklart hur vi ska mäta dem eller att det ens är praktiskt möjligt. Och även om vi kände till och kunde mäta alla bakomliggande variabler, vet vi inte hur vi ska kontrollera för dem. Den linjära och additiva regressionskvationen är bara en av många möjligheter. Av dessa skäl finns det nästan alltid en risk för att våra samband är spuriösa, trots att vi gjort vårt bästa för att isolera dem från andra faktorer. Därför är det aldrig fel att visa viss ödmjukhet när man presenterar sina regressionsresultat.