

# **Mediatie-analyse**

## College 4+

### Cursus PMC Statistiek Plus

Harry Ganzeboom

1 maart 2019

# Hoofdpunten

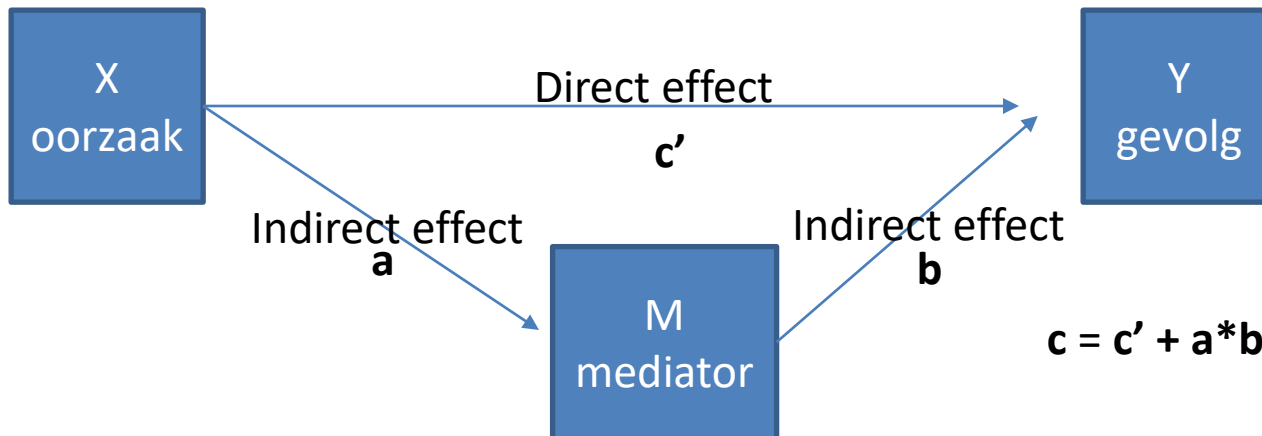

- Wat is mediatie? Wat is confounding?
- Waarschuwing: Mediatie is geen moderatie!!
- Multipele regressie: hoe werkt het?
- Mediatie-analyse via multiple regressie
  - Stapsgewijze regressie
  - Berekening samenstelling indirect effecten
  - Toetsing van significant indirect effect
- Stappenplan

# MEDIATIE

# Mediatie-analyse

- Mediatie-analyse: in hoeverre verloopt de invloed van een oorzaakvariabele X op een gevolgvariabele Y via een tussenliggende variabele M?
- Voorbeeld: in hoeverre hebben vrouwen minder inkomen dan mannen omdat vrouwen minder uren werken?
  - X: sekse
  - Y: inkomen
  - M: arbeidsaanbod (aantal uren betaalde arbeid)
- X: oorzaak, onafhankelijke (*independent*) variabele
- Y: gevolg, uitkomst, afhankelijke (*dependent*) variabele
- M: mediator, mechanisme, tussenliggende variabele

# Causaal model



# MEDIATIE IS GEEN MODERATIE!!

- In wetenschappelijke literatuur wordt **mediatie** vaak besproken in samenhang met **moderatie**: Baron, Reuben M. and David A. Kenny. 1986. "The Moderator-Mediator Variable Distinction in Social Psychological Research: Conceptual, Strategic, and Statistical Considerations." *Journal of Personality and Social Psychology* 51(6):1173–82.
- Aan Baron & Kenny hebben we ook de labeling van de effecten **c**, **c'**, **a**, **b** te danken.
- Wij bespreken moderatie in een volgend college. Hier alvast de waarschuwingen:
  - Studenten (maar **niet** alleen studenten...) zijn vaak in de war over het onderscheid tussen mediatie en moderatie.
  - Mediatie en moderatie zijn twee heel verschillende probleemstellingen (die je beide met multiple regressie te lijf gaat). Bij mediatie gaat het om **indirecte effecten**, bij moderatie om **interactie-effecten**.
  - Mediatie is wel verwant met confounding (de invloed van achterliggende variabelen)
- **Mediatie**: in welke mate verloopt de invloed van X op Y via een tussenliggende variabele M?
- **Confounding**: in welke mate wordt de correlatie tussen X en Y geproduceerd door een achterliggende variabele Z?
- **Moderatie**: in welke mate verandert een (tussenliggende of achterliggende) variabele de invloed van X op Y?

# Totaal, direct en indirect effect

- **Totaal effect:** wat is de invloed van X op Y als je niet rekening houdt met de mediator M?
- **Indirect effect:** welke deel van deze invloed verloopt via M:  $X \rightarrow M \rightarrow Y$ ?
- **Direct effect:** welk deel van deze invloed verloopt NIET via M:  $X \rightarrow Y \parallel M$ . [||| |: *wanneer we M constant houden*]
- Mediatie-analyse stelt je in staat deze effecten keurig te kwantificeren:

$$\textbf{Totaal effect = indirect effect + direct effect}$$

- Direct effect is eigenlijk geen gelukkige benaming. Beter zou zijn: residueel effect, onverklaard effect.
- Als het directe effect 0 is, kun je spreken van **volledige** mediatie, anders van **partiële** mediatie.

# Correlatie en totaal effect

- Het totaal effect  $X \rightarrow Y$  is onderdeel van de correlatie:
  - Correlatie = totaal effect + schijneffect
  - Schijneffecten = correlatie – totaal effect
- Het is gebruikelijk om in mediatie in gestandaardiseerde termen te spreken (correlatie en beta), maar het kan ook ongestandaardiseerd (covariante en B).



# Constanthouden

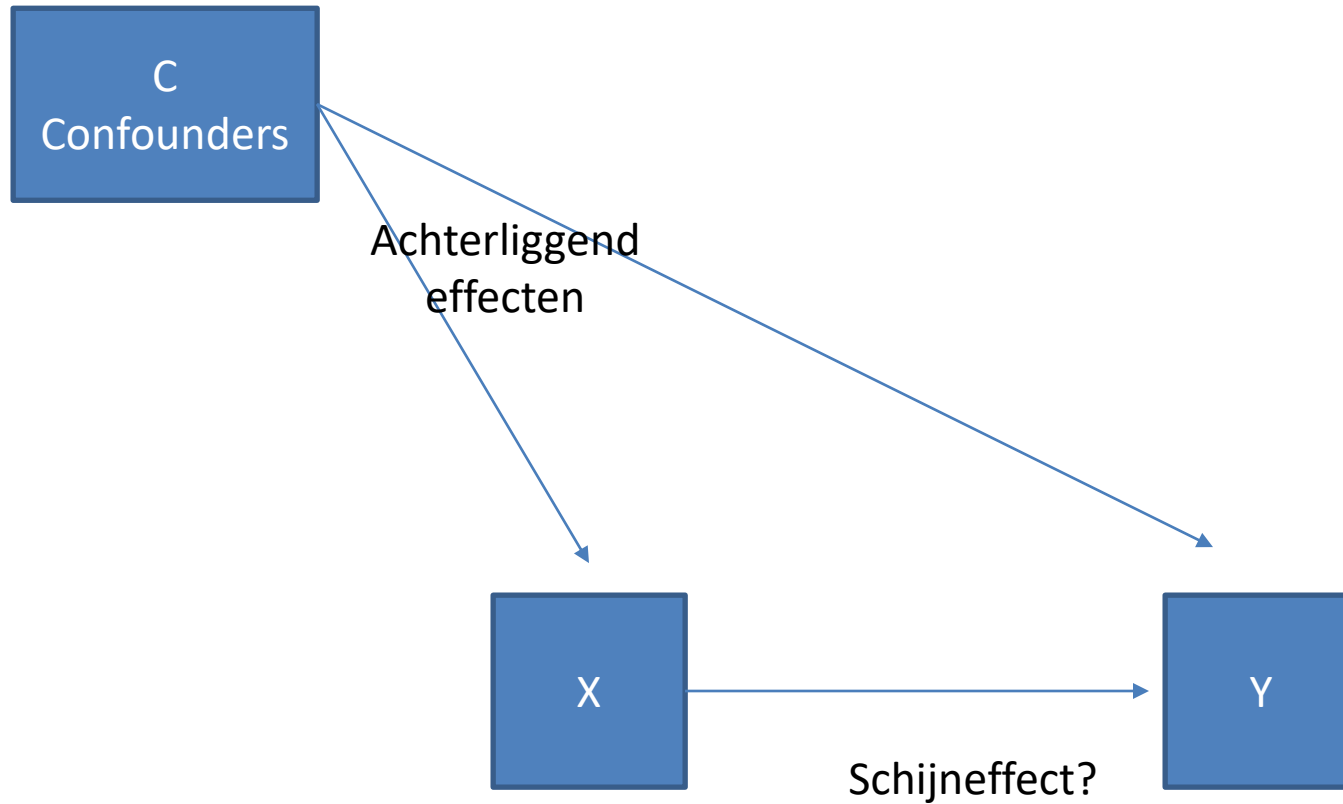
- Om mediatie en confounding te kwantificeren, moeten we de invloed  $X \rightarrow Y$  berekenen bij constant houden van de andere betrokken variabelen: M (bij mediatie), C (bij confounding).
- Het constant houden van een andere variabele kunnen we uitvoeren met tabellen met conditionele gemiddelden (tabelsplitsing, tabellelaboratie), maar in de praktijk doen we het altijd met Multiple Regression, oftewel het *(OLS) linear model*.
- Analyse van mediatie (en ook confounding) komt uiteindelijk neer op:
  - het berekenen van twee regressiemodellen;
  - nabewerking van de resultaten via:
    - berekening direct en indirect effect
    - toetsen van significantie van het indirect effect via de Sobel-test

# Confounding

# CONFOUNDING

- Confounding == gemeenschappelijk (achterliggende) oorzaak.
- Bekende (afgezaagde) voorbeelden:
  - Hoe meer ooievaars in een gebied, des te hoger het geboortecijfer.
  - Hoe groter de schoenmaat, des te hoger het IQ.
  - Hoe meer brandweerlieden bij een brand, des te groter de schade.
  - Kinderen die met een nachtlampje gaan slapen, worden later bijziend.
- We spreken over *spurious effects*: schijnbare invloed.
- NB: niet schijncorrelatie, het is een schijneffect. De correlatie bestaat wel, het effect bestaat niet.

# Het causaal model bij confounding



# Confounding

- Bij confounding analyseer je de samenhang tussen  $X$  en  $Y$  met uitschakeling van de achterliggende oorzaken van  $X$  en  $Y$ .
- Bij volledige confounding: de relatie van  $X \rightarrow Y$  verdwijnt bij constant houden van  $C$ .
- Gedeeltelijke confounding: de relatie van  $X \rightarrow Y$  verzwakt bij constant houden van  $C$ .
- Suppressie: de relatie van  $X \rightarrow Y$  versterkt bij constant houden van  $C$ .

# Confounding en mediatie

- Confounding en mediatie lijken sterk op elkaar en zijn eigenlijk ***twee perspectieven op hetzelfde causale model.***
- De statistische behandeling van confounding en mediatie is identiek: wat gebeurt er met  $X \rightarrow Y$  als je C / M (controlevariabelen) constant houdt?
- Maar de interpretatie is radicaal verschillend:
  - Confounding: hoe sterk is het zuivere effect  $X \rightarrow Y$ . Is er wel een oorzaak-gevolg relatie?
  - Mediation: hoe verloopt het effect  $X \rightarrow Y$ ? Hoe zit de oorzaak-gevolg relatie in elkaar?
- Het verschil wordt gemaakt door wat je als primaire oorzaak-gevolg relatie bekijkt. Het zit in je hoofd.

# Causale volgorde

- Welke variabele als  $X$ ,  $Y$ ,  $M$  of  $C$  optreedt, is een aanname (assumptie) van de onderzoeker. Je kunt dit niet zien aan de statistische output.
- De onderzoeker dient te argumenten wat de causale volgorde van de variabelen is: wat kan oorzaak zijn en wat gevolg?
- Meest gebruikte argumenten voor het kiezen van een volgorde:
  - Optreden in de tijd, levensloop.
  - Bv. eerst geslacht, geboortjaar, dan opleiding, dan arbeidsaanbod, en ten slotte inkomen.

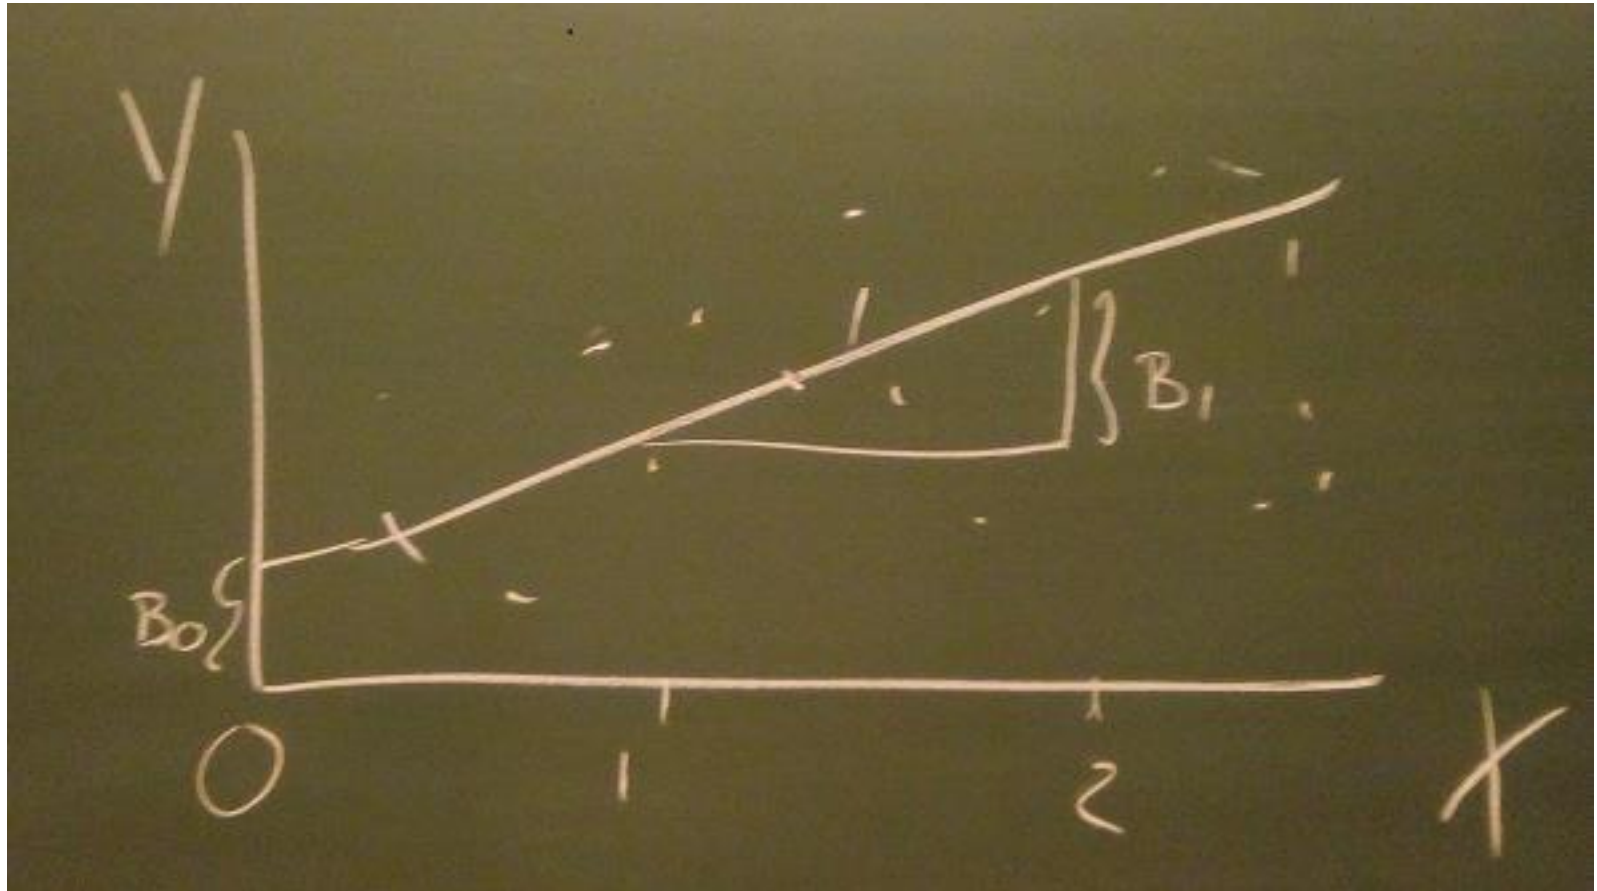
# MULTIPELE REGRESSIE



# Het enkelvoudig lineair model (*simple regression*)

- Het enkelvoudig lineair model luidt:
  - $Y = B_0 + B_1 * X_1$  (ook wel:  $Y = a + b * X$ )
- Het model bestaat uit de formule van een best passende rechte lijn. Hierin zijn:
  - $B_0$ : de constante / *intercept* = de verwachting voor  $Y$  als  $X_1 = 0$
  - $B_1$ : de hellingshoek / *slope* = hoeveel  $Y$  naar verwachting toeneemt / afneemt als  $X_1$  een eenheid groter wordt
- De best passende lijn wordt (door SPSS Regression) berekend via de methode van *Ordinary Least Squares* (OLS = kleinste kwadratenmethode).

# OLS simple regression



# Het meervoudig lineair model (*multiple regression*)

- Model:  $Y = B_0 + B_1 * X_1 + B_2 * X_2 + \dots$
- (het voorbeeld is voor twee X-variabelen, maar uitbreidbaar naar –tig X-en)
- Berekening van het best passende model vindt opnieuw plaats (door SPSS Regression) met de OLS (kleinste kwadraten) methode.
- $B_0$ : de verwachting voor Y, wanneer  $X_1 = X_2 = 0$ .
- $B_1$ : de toe-/afname van Y wanneer  $X_1$  met een eenheid toeneemt, waarbij  $X_2$  constant wordt gehouden.
- $B_2$ : de toe-/afname van Y wanneer  $X_2$  met een eenheid toeneemt, waarbij  $X_1$  constant wordt gehouden.
- De interpretatie van  $B_1$  en  $B_2$  is **partieel**: we houden de andere X-variabele constant.

# Constant houden

- Het bijzondere van het MR model is de **partiële interpretatie** van de B-coëfficiënten. Het levert je een beeld op van de unieke invloed van een X-variabele op Y, terwijl je de invloed van de andere X-variabelen uitschakelt / neutraliseert door deze constant te houden.
- Het MR model is niet de enige methode van constant houden, maar wel een heel algemeen toepasbare, in het bijzonder als het om veelwaardige (bv. continue) variabele gaat.
- Een alternatieve, inzichtelijke maar onbruikbare methode is constant houden via tabelsplitsing ('table-elaboration').

# Een voorbeeld met **twee** dichotome X-variabelen

- Wanneer we twee dichotome X-variabelen hebben, kunnen we ook een (tabel)analyse met conditionele gemiddelden gebruiken
- Voorbeeld:
  - Y: inkomen (continu)
  - X1: vrouw (0/1)
  - X2: full-time werk (0/1) meer of minder dan 20 uur werken.
- Dit kan zowel met conditionele gemiddelden als met een regressie-model.

# Voorbeeld in SPSS

**Tabel 1: Conditionele gemiddelden van Inkomen en arbeidsaanbod (al dan niet FULLTIME) voor mannen en vrouwen**

FEMALE		FULLTIME	PINC
0	Mean	0.98	2617
	N	384	384
1	Mean	0.84	1820
	N	366	366
Total	Mean	0.91	2228
	N	750	750

Fulltime: > 20 uur per week

Conclusies:

- Mannen werken 98% fulltime, vrouwen 84%
- Mannen verdienen  $2617 - 1820 = 797$  euro (per maand) meer dan vrouwen

# Conditionele gemiddelden

**Tabel 2: Conditionele gemiddelden van Inkomen en arbeidsaanbod voor mannen en vrouwen als ze fulltime of parttime werken**

<b>FULLTIME</b>	<b>FEMALE</b>	<b>Mean</b>	<b>N</b>
<b>0</b>	<b>0</b>	<b>1933</b>	<b>6</b>
	<b>1</b>	<b>1192</b>	<b>60</b>
	<b>Total</b>	<b>1259</b>	<b>66</b>
<b>1</b>	<b>0</b>	<b>2628</b>	<b>378</b>
	<b>1</b>	<b>1943</b>	<b>306</b>
	<b>Total</b>	<b>2321</b>	<b>684</b>
<b>Total</b>	<b>0</b>	<b>2617</b>	<b>384</b>
	<b>1</b>	<b>1820</b>	<b>366</b>
	<b>Total</b>	<b>2228</b>	<b>750</b>

***Binnen elke rij van FULLTIME is het arbeidsaanbod constant (0 of 1) !!***

Conclusies over inkomensverschil tussen vrouwen en mannen :

- Voor parttimers is het verschil  $1192 - 1933 = -741$
- Voor fulltimers is het verschil  $1943 - 2628 = -685$
- Gemiddeld (gewogen) is het  $(66/750) * (-741) + (684/750) * (-685) = -687$

# Enkelvoudige regressie

**Tabel 3: Inkomensverschil tussen mannen en vrouwen als lineair model**

---

---

	<u>B</u>	<u>SE</u>	<u>Beta</u>	t	p
1					
(Constant)	2617	49		53.4	0.000
FEMALE	-797	70	-0.383	-11.4	0.000

---

---

Conclusies:

- Vrouwen verdienen 797 euro minder dan mannen
- Het inkomensverschil is dik significant (t=-11.4).



# Multiple regressie

**Tabel 4: Inkomensverschil tussen mannen en vrouwen en tussen parttimers en fulltimers als multiple (meervoudig) lineair model**

Model		B	SE	Beta	t	P
1	(Constant)	1884	133		14.2	0.000
	FEMALE	-687	71	-0.330	-9.6	0.000
	FULLTIME	745	126	0.203	5.9	0.000

## Conclusies:

- Mannen die part-time werken hebben een verwacht inkomen van 1884.
- Full-timers verdienen gemiddeld 745 euro meer dan parttimers, als je rekening houdt met de (gecontroleerde) inkomenschillen tussen mannen en vrouwen
- Vrouwen verdienen gemiddeld 687 euro minder dan mannen, als je rekening houdt met het gecontroleerde verschil in inkomen tussen fulltime en parttime werken.
- Het inkomensverschil tussen mannen en vrouwen is verminderd van -797 naar -687 door het constant houden van full-time werken.

# Een voorbeeld met continue M

- Het is natuurlijk een vergroving om het verschil in arbeidsaanbod tussen mannen en vrouwen te vereenvoudigen tot het al dan niet full-time (= meer of minder dan 20 (!) uur) werken.
- We willen liever arbeidsaanbod als continue variabele (het preciese aantal uren werk per week) constant houden.
- Met tabelanalyse gaat dit moeilijk (je zou heel veel tabellen moeten maken en de resultaten worden erg onregelmatig door kleine aantallen), maar het gaat heel goed met MR.

# Voorbeeld in SPSS

**Tabel 5: Verwacht inkomensverschil tussen mannen en vrouwen zonder en met constant houden van arbeidsaanbod (=aantal uren betaalde arbeid)**

Model		B	SE	Beta	t	Sig.
1	(Constant)	2617	49		53.4	0.000
	FEMALE	-797	70	-0.383	-11.4	0.000
2	(Constant)	810	200		4.0	0.000
	FEMALE	-417	78	-0.200	-5.3	0.000
	HOURS	47.7	5.1	0.349	9.3	0.000

## Conclusies:

- Per uur (per week) verdient men gemiddeld bijna 48 euro (per maand!)
- Als je rekening houdt met het aantal gewerkte uren, is bijna de helft van het inkomensverschil tussen mannen en vrouwen verklaard

# STATISTISCH UITSTAPJE

# B en Beta

- Het geschatte regressiemodel staat in de kolom B, die achtereenvolgens de coëfficiënten  $B_0$ ,  $B_1$ ,  $B_2$  etc bevat.  
$$Y = B_0 + B_1 * X_1 + B_2 * X_2 + \text{etc.}$$
- Bij een  $X$  is dit de formule van een rechte lijn, die je gemakkelijk kunt tekenen. Bij meer dan een  $X$  is dit de formule van een hypervlak en is een grafiek niet meer te tekenen.
- Beta is hetzelfde regressiemodel, maar nu in gestandaardiseerde termen  $zX$  en  $zY$ :  $zX = (X - \text{Mean}(X))/\text{SD}(X)$  en  $zY = (Y - \text{Mean}(Y))/\text{SD}(Y)$ .
- Beta-coëfficiënten variëren tussen -1 en +1 (zoals correlaties) en kunnen daarom gemakkelijk met elkaar vergeleken worden.

# SE

- SE is het centrale ding in de inferentiële statistiek.
- Je leert wat een SE is en hoe je hem uit moet rekenen doorgaans in verband met een gemiddelde [SEMEAN =  $SD/\sqrt{N}$ ] en een proportie [SE(P) =  $\sqrt{((1-P)*P)/N}$ ], maar het is belangrijk te weten dat SE's over alle statistische grootheden bestaan, waaronder de regressiecoëfficiënten B.
- Daarom: Wat is een SE en wat kun je ermee doen?

# Wat is een SE?

- Een steekproefgrootte (zoals een correlatie,  $B$ , Beta, gemiddelde, proportie, SD) is niet hetzelfde als de overeenkomstige populatiegrootte.
- We zijn in de populatiegrootte geïnteresseerd, de steekproefgrootte is daarvan slechts een schatting, die ook anders had kunnen uitvallen.
- Maar hoeveel anders had het kunnen uitvallen? Daarvoor doen we een gedachtenexperiment: de steekproevenverdeling (sampling distribution).

# Steekproevenverdeling

- Stel: we trekken een groot aantal steekproeven (van grootte  $N$ ) en noteren de uitkomst van een bepaalde statistische grootheid (bv.  $B_1$ ).
- Over de verdeling van de grootheid bij een groot aantal (denkbeeldige) steekproeven, weten we intuïtief:
  - Deze verdeling is gecentreerd rondom de populatiewaarde: gemiddeld komt er de populatiewaarde uit.
  - De afwijkingen van de populatiewaarde zijn normaal verdeeld: kleine afwijkingen tussen steekproefwaarden en populatiewaarde komen veel vaker voor dan grote afwijkingen.
  - Als  $N$  groter is, zullen de afwijkingen tussen steekproefwaarden en populatiewaarde gemiddelde kleiner zijn: de SD van de steekproevenverdeling is dan kleiner.



# SE: SD van de steekproevenverdeling

- De SD van een steekproevenverdeling heeft een bijzonder naam: de Standard Error (ook: Sampling Error of Standaardfout).
- Omdat (en voorzover) de steekproevenverdeling normaal is, zou het mooi zijn als we de SE zouden weten: dan weten we immers gelijk met welke waarschijnlijkheid een bepaalde afwijking van de populatiewaarde optreedt.
- Gelukkig hebben knappe statistici formules ontwikkeld waarmee SE's geschat kunnen worden. Die hebben ze doorgegeven aan SPSS, en voor ons gewone stervelingen rekent SPSS het uit en drukt het af.
- Voor ons is een SE dus weinig anders dan een getal in de output; niettemin moeten we wel begrijpen wat er achter zit en wat je ermee kunt doen.
- Een paar formules van SE's staan al hierboven. Een completere collectie vind je hier: [http://www.harryganzeboom.nl/Teaching/formules\\_HG.pdf](http://www.harryganzeboom.nl/Teaching/formules_HG.pdf).
- Formules voor een SE(B) zijn veel ingewikkelder dan die voor een gemiddelde.

# Toepassing 1: Schatten, Betrouwbaarheidsintervallen

- Als je eenmaal een SE weet, kun je daarmee een betrouwbaarheidsinterval (CI: Confidence Interval) berekenen.
- Doorgaans: CI<sub>95</sub>: steekproefwaarde  $\pm 1.96 * SE$ .
- Interpretatie: als je heel vaak een betrouwbaarheidsintervallen berekent, bevat die in 19/20 gevallen de ware populatiewaarden – in 5% van je schattingen niet.
- NB: Confidence: steekproefbetrouwbaarheid. Dit is iets anders dan Reliability: meetbetrouwbaarheid. In het Nederlands hebben we helaas daarvoor maar een woord.

# Toepassing 2: Toetsing van (statistische) significantie.

- Bij significantie toetsing stellen we een  $H_0$  op: een veronderstelling dat de populatiewaarde van de bestudeerde grootte 0 is.
- Rondom deze denkbeeldige grootte kunnen we weer een CI opstellen:  $0 \pm 1.96 * SE$ .
- We berekenen hoeveel SE onze steekproefwaarde van de  $H_0$  af ligt:  $t = \text{steekproefwaarde} / SE$ .
- Als  $t > 1.96$  (of  $t < -1.96$ ) dan kunnen we concluderen dat de veronderstelde  $H_0$  met minder dan 5% kans waar is – we verwerpen dan de  $H_0$ .
- Kort door de bocht: toetsen is hetzelfde als kijken of de steekproefwaarde in het CI van de  $H_0$  ligt.

# Enige nuanceringen

- Strikt genomen zijn steekproevenverdeling niet normaal, maar t-verdeeld. Normale en t-verdelingen gelijken sterk bij  $N > 35$  en zijn praktisch niet te onderscheiden bij  $N > 100$ .
- SPSS past de juiste verdeling (Normaal of T toe) en geeft je de bijbehorende overschrijdingskans ('Sig'): de kans dat het steekproefresultaat zou verschijnen in een random sample als de  $H_0$  opgaat in de populatie.

# H0 bij regressie-analyse


- SPSS veronderstelt bij elke toetsing  $H_0 = 0$ .
- Voor regressie-coëfficiënten  $B_1$ ,  $B_2$  etc. is dit een mooie veronderstelling, die betekent: geen effect.
- Voor de constante  $B_0$  is ook de veronderstelde  $H_0: B_0 = 0$ . Dat is heel vaak een zinloze veronderstelling en de betreffende toetsing is niet interessant.

# MEDIATIE-ANALYSE VIA MR

# Mediatie-analyse via MR

- Bij multiple regressie maken we nog geen veronderstelling over de causale volgorde van  $X_1$  en  $X_2$ .
- Pas door te beslissen welke causale volgorde er bestaat tussen  $X_1$  en  $X_2$  wordt het een mediatie-analyse, met een direct en een indirect effect.
- Welke van de twee is de oorzaak variabele en welke de tussenliggende variabele?
- In ons voorbeeld is het antwoord niet moeilijk: sekse ( $X$ ) gaat vooraf aan arbeidsaanbod ( $M$ ).

# Mediatie-model





# Conclusies over mediatie

- Het totale effect Sekse → Inkomen: -797 euro
- Het directe (partiële, overblijvende) effect: -417 euro
- Het indirecte (verklaarde) effect = totaal effect – direct effect = -380 euro.

*NB: dit directe effect is niet per se 'discriminatie van vrouwen op de arbeidsmarkt'. Andere mogelijke mediators zijn: opleiding, beroep, arbeidservaring.*

Over het indirecte effect komen nu twee vragen op:

- Hoe is het indirecte effect samengesteld?
- Is het indirecte effect statistisch significant?

# Samenstelling indirect effect

- We kunnen de omvang van het indirecte effect  $X \rightarrow M \rightarrow Y$  berekenen via vermenigvuldiging van de effecten **a** en **b**.
- Hiervoor moeten we **twee modellen** berekenen:
  - $B(X \rightarrow M)$  ( $M$  is de *dependent variable*)
  - $B(M \rightarrow Y \mid X)$  ( $Y$  is de *dependent variable*)Dit kan in SPSS alleen via twee afzonderlijke regressie-modellen.
- De berekening werkt zowel met ongestandaardiseerde ( $B$ ) als gestandaardiseerde (Beta) coëfficiënten. We geven doorgaans de voorkeur aan de Beta coëfficiënten.

# Berekening indirect effect

- We kunnen het indirect effect berekenen via vermenigvuldiging van de beide effecten (**a\*b**)
- Bij FULLTIME als mediator:  
$$\mathbf{a*b} = -.15 * 745 = -112 \text{ euro}$$
- Bij HOURS als mediator:  
$$\mathbf{a*b} = -8 * 47.6 = -381 \text{ euro}$$

# Samenstelling totaal effect

- Met Fulltime als mediator:
  - $-112 - 687 = -797$
- Met Hours als mediator
  - $-381 - 417 = -797$

# Berekening gestandaardiseerde direct en indirect effect

- Het is in mediatie-analyse gebruikelijk om indirect en direct effect (ook) uit te drukken in gestandaardiseerde coëfficiënten (Beta).
- Gestandaardiseerde effecten zijn allemaal in sterkte met elkaar vergelijkbaar.
- Dat is hier belangrijk omdat bij verschillende afhankelijke variabelen (M en Y) de meeteenheid van de B effecten niet vergelijkbaar is: we kunnen van de ongestandaardiseerde effecten niet de relatieve sterkte zien.

# Gestandaardiseerde berekening

- Met FULLTIME als mediator:
  - Totaal effect =  $c = -0.383$
  - Direct effect =  $c' = -0.330$
  - Indirect effect =  $a*b = -0.262*0.203 = -0.053$
- Met HOURS als mediator:
  - Totaal effect =  $c = -0.383$
  - Direct effect =  $c' = -0.200$
  - Indirect effect =  $a*b = -0.525*0.349 = -0.183$
- Uit deze analyse leren we drie dingen:
  - Arbeidsaanbod (als je het goed operationaliseert) is voor bijna 50% verantwoordelijk voor de inkomensverschillen tussen mannen en vrouwen.
  - Het sterke verschil in arbeidsaanbod (0.523) tussen mannen en vrouwen is belangrijker voor het indirecte effect dan het uurloon-effect (0.349).
  - Het maakt veel uit of arbeidsaanbod operationaliseert als al dan niet FULL-TIME werken of als continu aantal HOURS → bij mediatie-analyse is de kwaliteit van meting van de mediator van cruciaal belang.

# Significantie indirect effect

- Aan de SPSS output kunnen we niet zien of het indirecte effect statistisch significant is.
- Toch is dat een heel belangrijke vraag.
- Aan de berekening van de SE van indirecte effecten en de daarop berustende significantietesten is een belangrijke bijdrage geleverd door de Amerikaanse socioloog (!) Michael Sobel.
- Zijn werk is gepopulariseerd in de website over de Sobeltest:  
<http://quantpsy.org/sobel/sobel.htm>

# Sobel-test

- Je kunt de sobel-test op twee manieren invoeren:
- Via de t-waarden van  $B(X \rightarrow M)$  en  $B(M \rightarrow Y \mid \mid X)$ .
- Via  $B(X \rightarrow M)$  en  $B(M \rightarrow Y \mid \mid X)$  zelf, en hun bijbehoren SE.
- Methode 1 geeft alleen een significantietest, methode 2 geeft ook de SE van het indirecte effect.



# Sobel-test

- Met HOURS als mediator:
  - $t(a) = -9.3$   $t(b) = 17.9 \rightarrow$  Sobel  $t: 8.0$
- Met FULLTIME als mediator:
  - $t(a) = -7.4$   $t(b) = 5.9 \rightarrow$  Sobel  $t: 4.6$
- Het indirecte effect is dus in beide gevallen statistisch significant ( $t > 1.96$ ).
- Dat hoeft niet zo af te lopen:
  - Als een van beide samenstellende effecten (a of b) niet significant is, is  $a*b$  nooit significant.
  - Als a of b (of allebei) marginaal significant is, is  $a*b$  vaak niet significant. Exacte uitslag geeft de sobel-test.

# Mediatie in de praktijk

- In de praktijk worden indirecte effecten en de sobel-test vaak niet berekend.
- Maar wordt volstaan met een stapsgewijze regressietabel, waarin naast elkaar worden gezet:
  - Model 1: Correlatie tussen X en Y als enkelvoudige regressie.
  - Model 2: Totaal effect van X op Y (multipelere regressie met constant houden van de confounders)
  - Model 3: Partiële effecten van X en M op Y (multipelere regressie met constant houden van confounders en mediators)
- Het commentaar gaat er dan over welke veranderingen optreden in totale en partiële effect van X op Y.
- Het effect van X op M wordt veelal niet bediscussieerd.

# Mediatie-analyse via stapsgewijze regressie

**Tabel 7a: Stapsgewijze regressie ter verklaring van inkomensverschillen tussen mannen en vrouwen via al dan niet full-time werken**

		B	SE	Beta	t
1	(Constant)	2617	49		53.4
	FEMALE	-797	70	-.383	-11.4
2	(Constant)	1918	100		19.2
	FEMALE	-526	76	-.253	-7.0
	FULLTIME	725	91	.289	7.9

# Mediatie-analyse via stapsgewijze regressie

**Tabel 7b: Stapsgewijze regressie ter verklaring van loonverschillen tussen mannen en vrouwen via aantal uren arbeidsaanbod**

	<u>Model 1</u>				<u>Model 2</u>			
	<u>B</u>	<u>SE</u>	<u>t</u>	<u>Beta</u>	<u>B</u>	<u>SE</u>	<u>t</u>	<u>Beta</u>
Constante	2617	49.0	53.4		810	200.3	4.0	
FEMALE	-797	70.2	-11.4	-0.383	-417	78.2	-5.3	-0.200
HOURS					47.7	5.14	9.3	0.349
adj R2				14.6%				23.3%

Y: Maandinkomen in euro's; FEMALE: 0/1; HOURS: 1-40. Sample: N=750 mannen en vrouwen, ISSP-NL 2013-2014

# De tweede regressie vergelijking

**Tabel 8a: Arbeidsaanbod van mannen en vrouwen (uren betaalde arbeid)**

Model		B	SE	Beta	t	Sig.
1	(Constant)	37.91	0.33		114.6	0.000
	FEMALE	-7.98	0.47	-0.525	-16.8	0.000

**Tabel 8b: Arbeidsaanbod van mannen en vrouwen (al dan niet full-time)**

Model		B	SE	Beta	t	Sig.
1	(Constant)	0.984	0.014		70.4	0.000
	FEMALE	-0.148	0.020	-0.262	-7.4	0.000

## Conclusies:

- Vrouwen werken minder uren (-8) en minder vaak fulltime (-15%) dan mannen.
- Het verschil in arbeidsaanbod is veel sterker wanneer je het arbeidsaanbod afmeet aan het aantal uren dan aan al dan niet full-time.

# Stappenplan mediatie

- Stap 1: bepaal de causale volgorde van je variabelen: wat is X, Y en M? Deze beslissing komt voort uit je design en theoretische overwegingen.
- Stap 2: Bereken regressiemodellen
  - a) Bereken model  $X \rightarrow Y$
  - b) Bereken model  $X, M \rightarrow Y$
  - c) Bereken model  $X \rightarrow M$Stap 2a en 2b kun je in SPSS handig combineren.
- Stap 3: Maak stapsgewijze regressietabel
- Stap 4: Bereken de sobel-test

# Appendix

- SPSS syntax staat afzonderlijk op Canvas