

Nederlandse Samenvatting

C.1 Introductie: Psychologische netwerken

Dit proefschrift beschrijft het schatten van netwerkstructuren op psychologische data: *netwerkpsychometrie*. Dit onderzoeksveld is ontstaan uit een vraag om psychologische verschijnselen, zoals het gezamenlijk voorkomen van depressieve symptomen als moeheid en concentratieproblemen, niet te conceptualiseren als reflectief aan een onderliggende latente trek, zoals depressie, maar juist als een gevolg van directe interacties tussen de gemeten eigenschappen: moeheid leidt tot concentratieproblemen. De opkomst van bijvoorbeeld een depressieve episode kan dan gezien worden als emergent gedrag in een systeem van interacterende componenten. Om deze systemen in kaart te brengen wordt gebruik gemaakt van netwerkmodellen. Om verwarring te voorkomen met, bijvoorbeeld, sociale netwerken worden deze netwerken aangeduid als *psychologische netwerken*.

Figuur C.1 laat een voorbeeld zien van een dergelijk psychologisch netwerk. Dit netwerk is een ongericht netwerk waarin variabelen worden weergegeven als knopen. De verbinding tussen knopen geeft weer hoe sterk twee variabelen samenhangen nadat er is gecontroleerd op alle andere variabelen in de dataset. De introductie beschrijft hoe dergelijke verbindingen kunnen worden geïnterpreteerd; een verbinding geeft de unieke variantie weer tussen twee variabelen die niet verklaard kan worden door andere variabelen. Deze verbindingen kunnen gezien worden als indicatief voor mogelijke causale relaties tussen twee variabelen. Daartegenover: het ontbreken van een verbinding indiceert dat twee variabelen mogelijk conditioneel onafhankelijk zijn. De introductie beschrijft verder hoe methoden uit de grafentheorie gebruikt kunnen worden om de verkregen netwerkstructuren te analyseren. Zo kan de belangrijkheid van knopen bepaald worden met behulp van centraliteitsmaten.

De introductie van deze psychologische netwerken, en de in dit proefschrift beschreven software en technologische ontwikkelingen, hebben geleid tot een sterke navolging in (met name klinisch) psychologisch onderzoek. Deel 1 van dit proefschrift is derhalve gericht tot empirische onderzoekers in de psychologie, met een nadruk op klinische psychologie. In Deel 1 wordt het schatten van netwerkstructu-



Figuur C.1: Voorbeeld van een psychologisch netwerk. Knopen geven variabelen weer (in dit geval items van een persoonlijkheidsvragenlijst) en verbindingen tussen knopen geven partiële correlaties weer.

ren geïntroduceerd, en tevens een kritische noot gelegd om overinterpretatie tegen te gaan. Naast empirisch onderzoek bleken de netwerkmodellen ook een belangrijke bijdrage te kunnen leveren aan methodologisch en psychometrisch onderzoek; psychologische netwerken zijn niet alleen contrasterend ten opzichte van klassieke psychometrie, maar juist ook aanvullend. Een netwerkmodel is niet een tegenpool van het latente-variabelenmodel, maar kan juist nieuwe inzichten geven aan het latente-variabelenmodel. Derhalve richten Deel 2 en Deel 3 zich voornamelijk op de overeenkomsten tussen het netwerkmodel en de klassieke psychometrie. Zo blijkt dat het netwerkmodel als formeel psychometrisch model kan worden gevormd en dat netwerkmodellen en latente-variabelenmodellen zelfs equivalent kunnen zijn. Tevens biedt de netwerkpsychometrie sterke, nieuwe visualisatietechnieken voor psychometrisch onderzoek.

C.2 Deel I: Netwerkpsychometrie voor de empirische wetenschapper

Hoofdstuk 2: Geregulariseerde netwerken van partiële correlaties


Dit hoofdstuk introduceert het meest gebruikte netwerkmodel voor psychologische netwerken: het *netwerk van partiële correlaties* (later in het proefschrift ook

een Gaussisch grafisch model genoemd). Dit is een netwerk waarin geobserveerde variabelen worden weergegeven als knopen. Verbindingen tussen knopen zijn gebaseerd op partiële correlaties tussen twee variabelen na conditioneren op alle andere variabelen. Deze netwerken moeten worden geschat op basis van data. Bij het schatten van een netwerk moet ook gekeken worden naar de *structuur* van het netwerk: welke knopen zijn met elkaar verbonden? Dit betekent dat het schatten van een netwerk gepaard gaat met een modelselectieprobleem. Doordat een netwerk een hoog-dimensioneel model is, is zowel het schatten van parameters als het uitvoeren van modelselectie niet triviaal. Er moet rekening gehouden worden met het feit dat de parameters niet ‘overfitten’ (te veel gebaseerd zijn op ruis) en dat de modelzoekruimte uitzonderlijk groot kan zijn. Een veel gebruikte oplossing is om gebruik te maken van een statistische techniek genaamd *regularisatie*. In regularisatie wordt doorgaans gebruik gemaakt van bestrafte grootste-aannemelijkheidsschatting (*penalized maximum likelihood estimation*) om overfitten tegen te gaan. Met name de variant genaamd de LASSO is veelbelovend voor het schatten van netwerken. De LASSO bestraft de som van absolute parameterwaardes, waardoor veel parameters in de schatting krimpen naar 0. Voor netwerken kan gebruik gemaakt worden van een variant van de LASSO genaamd de ‘grafische LASSO’ (glasso).

Om glasso te gebruiken moet eerst een schatting worden verkregen van de variantie-covariantie matrix. Wanneer de data continu zijn, kan deze worden verkregen door Pearson correlatiecoëfficiënten uit te rekenen. Voor ordinale data kan gebruik gemaakt worden van polychorische correlatiecoëfficiënten. Vervolgens berekent glasso een spaarzaam netwerk van partiële correlaties. De glasso berekent echter niet één netwerk, maar een *reeks* aan netwerken: van netwerken met veel verbindingen tot een netwerk met geen verbindingen. Om vervolgens een enkel netwerk te selecteren kan gebruik gemaakt worden van modelselectie. Met name het uitgebreide Bayesiaans informatie criterium (*extended Bayesian information criterion*; EBIC) werkt goed in het selecteren van de juiste netwerkstructuur. De EBIC maakt gebruik van een instelparameter, γ , die tussen 0 en 1 kan worden gezet. Bij $\gamma = 0$ prefereert de EBIC complexere modellen en bij $\gamma = 1$ prefereert de EBIC simpelere modellen. Gebruikelijk zijn 0.25 en 0.5 goede waardes voor deze instelparameter. Vervolgens wordt het netwerk met de laagste EBIC geselecteerd. Figuur C.2 geeft dit selectieproces grafisch weer. Deze methode is geïmplementeerd in het R pakket *qgraph*.¹

Het hoofdstuk presenteert een lijst van mogelijke problemen die zich kunnen voordoen bij het schatten van netwerken van partiële correlaties. Met name wanneer polychorische correlatiecoëfficiënten worden gebruikt kunnen problemen ontstaan wanneer er te weinig data zijn (bijv. de correlatiematrix kan niet positief semi-definiet zijn). Het hoofdstuk concludeert met een simulatiestudie die laat zien dat de beschreven methode goed werkt. De schatting van een Ising model voor binaire variabelen en een gemengd grafisch model voor een mix van categorische en continue variabelen volgt ruwweg hetzelfde proces als het hier beschreven.

¹<https://github.com/SachaEpskamp/qgraph>



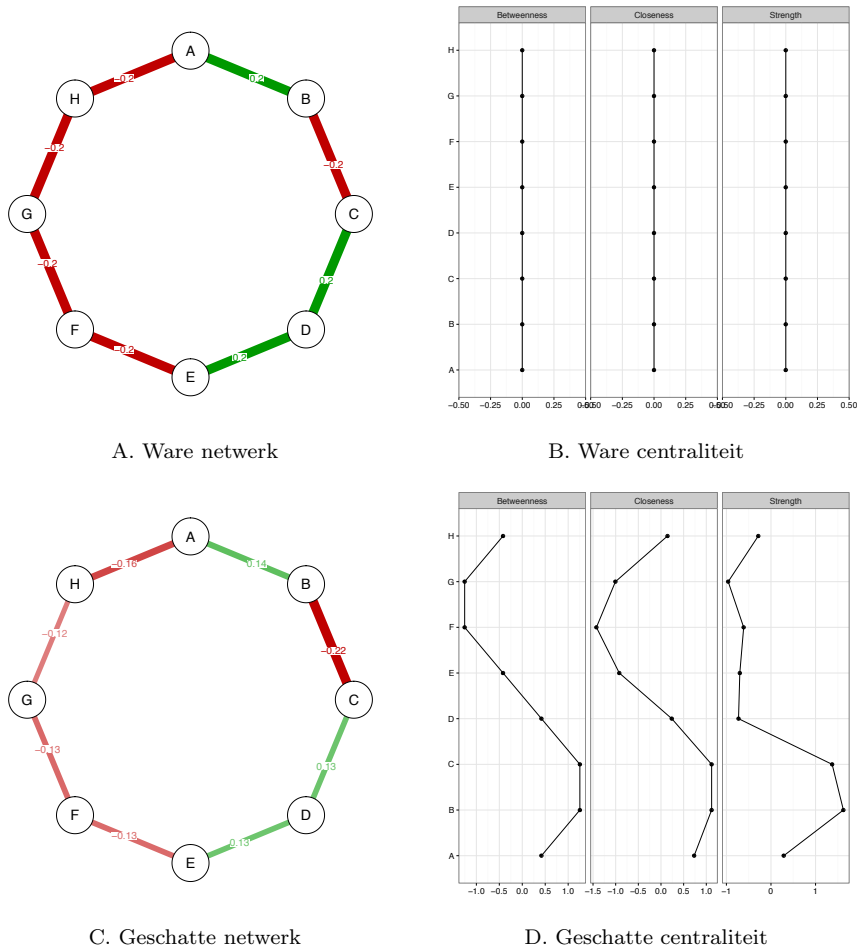
Figuur C.2: Tien verschillende geschatte netwerken van partiële correlaties met behulp van LASSO regularisatie. Een reeks van netwerken kan worden verkregen: van een netwerk met veel verbindingen tot een netwerk met geen verbindingen. Hoe goed elk model past wordt beoordeeld met de EBIC, waarbij de instelparameter γ op 0, 0.25 of 0.5 wordt gezet. De dik-gedrukte waarde is de laagste EBIC gegeven een bepaalde waarde van γ : dit netwerk wordt gekozen als beste model.

Hoofdstuk 3: Accuraatheid van psychologische netwerken

Dit hoofdstuk beargumenteert dat bij het analyseren van netwerken rekening moet worden gehouden met het feit dat deze zijn gebaseerd op een *steekproef*. Zoals beschreven in Hoofdstuk 2 moet een netwerk geschat worden op basis van data. Aangezien deze data een steekproef behelzen, zijn zelfs de beste schatters onderhevig aan ruis en niet perfect. Als hier geen rekening mee wordt gehouden, kan er een verkeerde conclusie worden getrokken op basis van een verkregen netwerkstructuur. Dit is onder meer belangrijk wanneer er gekeken wordt naar de *centraliteit* van knopen in het netwerk. Figuur C.3 laat een voorbeeld zien waarin knopen niet meer of minder centraal zijn van elkaar in het ware netwerk (Paneel A). In een netwerk dat geschat is op basis van een steekproef (Paneel C) verschillen knopen echter wel in centraliteit. Deze verschillen komen echter puur door ruis, en een substantiële interpretatie van centraliteit in dit netwerk zou niet gepast zijn. Het hoofdstuk beargumenteert dat door middel van *bootstrap* methoden inzicht kan worden verkregen in deze onzekerheid. In bootstrap methoden worden observaties (rijen in de dataset) willekeurig getrokken om nieuwe datasets te genereren. Op elk van deze datasets wordt vervolgens een netwerk geschat; de parameterwaarden van deze netwerken geven inzicht in de variabiliteit van de schatter. Deze methoden zijn geïmplementeerd in het R pakket *bootnet*.²

Het hoofdstuk beschrijft een driestappenplan om de mate van interpreteerbaarheid van gevonden verschillen te beoordelen. Deze stappen worden gepresenteerd in een afnemende mate van belangrijkheid. In stap A wordt de *non-parametrische bootstrap* (trekken van een zelfde aantal rijen als in de oorspronkelijke data met teruglegging) gebruikt om betrouwbaarheidsintervallen te schatten voor de netwerkverbindingen. Als deze betrouwbaarheidsintervallen groot zijn, is de sterkte van een verbinding in het netwerk moeilijk te interpreteren. Dergelijke betrouwbaarheidsintervallen kunnen echter niet gevormd worden voor centraliteitsmaten. In stap B wordt de interpreteerbaarheid van centraliteitsmaten gekwantificeerd door te kijken naar de stabiliteit van centraliteitsmaten met minder observaties. Dat wil zeggen, blijft de interpretatie van centraliteit hetzelfde op basis van een subset van de data. Om deze stabiliteit te bekijken, wordt gebruik gemaakt van de *subset bootstrap* (trekken van minder aantal rijen als in de oorspronkelijke data zonder teruglegging). Om dit te kwantificeren stelt het hoofdstuk de correlatiestabiliteitscoëfficiënt (*CS*-coëfficiënt) voor: $CS(\text{cor} = 0.7) = X$ betekent dat maximaal een proportie van X observaties uit de data kan worden gehaald om met 95% zekerheid te stellen dat de correlatie tussen de oorspronkelijke centraliteit en de centraliteit op basis van een willekeurige subset boven 0.7 blijft. Als deze maat onder 0.25 is, is de centraliteit niet te interpreteren. Idealiter is deze maat boven 0.5. In stap C kan een statistische test (*bootstrapped difference test*) worden uitgevoerd om te toetsen of verschillen tussen verbindingsterktes en centraliteit van knopen significant zijn. Gebruikmakend van deze nieuwe methoden blijkt dat de verschillen in centraliteit in Figuur C.3 zowel niet significant als niet stabiel zijn. Het hoofdstuk concludeert met stap-voor-stap instructies over het gebruik van *bootnet* en drie simulatiestudies over de *CS*-coëfficiënt en significantietoetsen.

²<https://github.com/SachaEpskamp/bootnet>



Figuur C.3: Paneel A laat een netwerk van partiële correlaties zien waaronder data zijn gesimuleerd. Paneel B laat de centraliteit zien (gestandaardiseerd als z -scores) volgens dit ‘ware’ netwerk. Het netwerk in Paneel A is geconstrueerd zodat geen enkele knoop meer of minder centraal is dan een andere knoop. In Paneel C is een netwerk te zien dat is geschat op gesimuleerde data ($N = 500$) onder het netwerk van Paneel A. Hoewel het geschatte netwerk van Paneel C goed lijkt op het ware netwerk van Paneel A is de schatting niet exact. Hierdoor zijn in het geschatte netwerk *wel* verschillen in centraliteit (Paneel D).

Hoofdstuk 4: De schattingsmethode van netwerken en spaarzaamheid

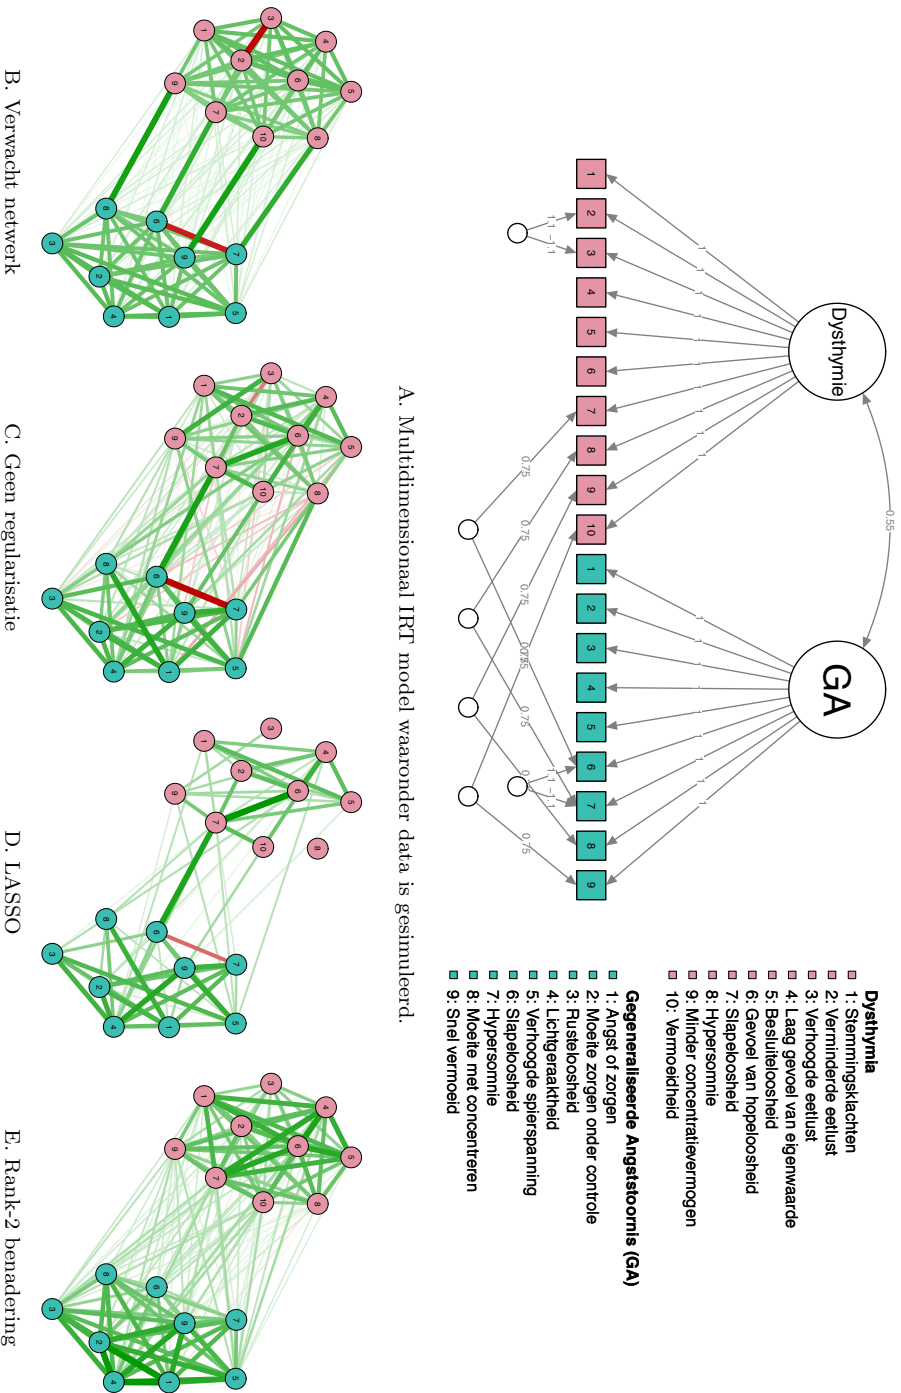
Dit hoofdstuk waarschuwt tegen het overinterpreteren van geschatte netwerken op psychologische data. Aangezien netwerkmodellen zeer nauw verbonden zijn aan latente-variabelenmodellen (zie Hoofdstuk 7 en Hoofdstuk 8) betekent het schatten van een netwerkmodel niet dat het datagenererende mechanisme niet een latente-variabelenmodel had kunnen zijn. Een latente-variabelenmodel leidt tot een netwerk dat niet spaarzaam is: alle knopen zijn met elkaar verbonden. Echter, als wel een spaarzaam netwerk wordt gevonden (er ontbreken meerdere mogelijke verbindingen in het netwerk), bijvoorbeeld door LASSO schatting te gebruiken, is dat geen evidentie dat een latente-variabelenmodel niet aan de data ten grondslag kan liggen. Dit komt doordat de schattingsmethode bepaalde assumpties doet over de ware netwerkstructuur die niet kunnen worden genegeerd. De LASSO neemt aan dat het ware netwerk spaarzaam is, en zal zodoende vaak een spaarzaam netwerk schatten. Een andere methode is om een netwerk te schatten dat een lage rang heeft. Deze methode kan goed een netwerk terugschatten dat overeenkomt met een latente-variabelenmodel, maar heeft juist weer als keerzijde dat nooit een spaarzaam netwerk zal worden geschat.

Figuur C.4 laat een voorbeeld zien van het effect van de schattingsmethode. Data waren gegenereerd volgens het latente-variabelenmodel in Paneel A, een Multidimensionaal IRT model (MIRT). Dit model is een hypothetisch model gebaseerd op de symptomen van dysthemie en gegeneraliseerde angststoornis. Omdat deze symptomen deels overlappen (bijv. slapeloosheid is een symptoom van beide stoornissen) en deels elkaar uitsluiten (bijv. slapeloosheid en hypersomnie) zijn residuele factoren toegevoegd. De symptomen laden alle even sterk op de latente factoren, en zijn dus *uitwisselbaar*. Het MIRT model is sterk verbonden aan het Ising model (zie Hoofdstuk 7). Paneel B laat het Ising model zien dat zou verwacht worden gegeven het ware MIRT model (geschat op 10 miljoen gesimuleerde observaties). Paneel C laat een Ising model zien dat zonder regularisatie is geschat,³ wat veel verbindingen oplevert (vooral negatieve) die niet overeenkomen met het ware model. Paneel D laat een Ising model zien geschat met LASSO regularisatie.⁴ Dit netwerk is spaarzaam en levert te weinig verbindingen op. De clustering wordt niet volledig teruggeschat en knopen hebben een verschillend aantal verbindingen terwijl deze uitwisselbare symptomen representeren. Paneel E, ten slotte, laat een lage rang benadering zien die juist niet in staat is de brug-symptomen terug te schatten.


Zonder te weten dat het latente-variabelenmodel het ware model is, had een onderzoeker mogelijk alleen het spaarzame netwerk van Paneel D bekeken, en vervolgens geconcludeerd dat het ware model niet een latente-variabelenmodel kan zijn. Deze conclusie zou echter niet gegrond zijn, aangezien de LASSO zorgt voor een spaarzaam netwerk. Het onderscheiden van dergelijke modellen is nog een groot open vraagstuk in de netwerkpsychometrie, en kan mogelijk niet gedaan worden zonder experimentele manipulatie. Onderzoekers moeten daarom rekening

³Gebruikmakend van het R pakket *IsingSampler*; <https://github.com/SachaEpskamp/IsingSampler>

⁴Gebruikmakend van het R pakket *IsingFit*; <https://github.com/cvborkulo/IsingFit>



Figuur C.4: Verschillende geschatte netwerken gegeven dat het ware model een latente-variabelenmodel is (Paneel A).



Figuur C.5: Temporeel (links) en gelijktijdig (rechts) netwerken gebaseerd op data van een klinische patiënt die 52 keer is gemeten over een periode van twee weken. Legenda van knopen: O = ‘ontspannen’; V = ‘verdrietig’; N = ‘nervuus’; C = ‘concentratie’; M = ‘moe’; P = ‘piekeren’; L = ‘lichamelijk ongemak’.

houden met het feit dat de schattingsmethode de netwerkstructuur beïnvloedt, waardoor sommige conclusies niet getrokken kunnen worden.

Hoofdstuk 5: Gepersonaliseerde netwerkmodellen in de psychopathologie

Dit hoofdstuk beschrijft hoe netwerkmodellen gebruikt kunnen worden in de klinische praktijk. Een patiënt kan meerdere keren per dag worden gemeten over een periode van enkele weken. Vervolgens kunnen statistische methoden gebruikt worden om de dynamiek van deze patiënt in kaart te brengen. Het meest eenvoudige model dat kan worden gebruikt is het vector-autoregressieve model (*vector-autoregression*; VAR). In VAR wordt doorgaans een *temporeel netwerk* berekend, dat de samenhang tussen variabelen laat zien tussen opeenvolgende tijdsblokken. Een voorbeeld van een temporeel netwerk is te zien in het linker paneel van Figuur C.5. Een verbinding in een dergelijk temporeel netwerk indiceert dat een gemeten variabele in een bepaald tijdsblok (bijv. moe) een andere variabele in het volgende tijdsblok (bijv. verdrietig) voorspelt. Een dergelijke relatie kan voorkomen als iemands moeheid van invloed is op iemands gevoel van verdriet.

De VAR-analyse levert naast het temporele netwerk ook een tweede netwerk op: het *gelijktijdige netwerk*. Een voorbeeld van een dergelijk netwerk is te zien in het rechter paneel van Figuur C.5. Dit netwerk is een netwerk van partiële correlaties tussen de residuen van de VAR-analyse, en laat relaties zien die niet verklaard kunnen worden door de temporele verbanden. Relaties die sneller zijn dan de intensiteit van meten en zich afspelen in het zelfde tijdsblok komen terecht in dit gelijktijdige netwerk. Dit hoofdstuk beargumenteert dat het gelijktijdige netwerk

naast het temporele netwerk ook waardevolle informatie kan bevatten, omdat relaties in de psychopathologie plausibel snel kunnen optreden. Een voorbeeld is de relatie:

hartkloppingen \rightarrow bang voor paniekaanval.

Een persoon die lijdt onder een paniekstoornis kan bang worden dat hij of zij een paniekaanval krijgt omdat hij of zij hartkloppingen voelt. Een dergelijke relatie speelt zich waarschijnlijk zeer snel af en zal niet terecht komen in het temporele netwerk. Deze relatie zal echter mogelijk wel te zien zijn in het gelijktijdige netwerk; in tijdsblokken wanneer deze persoon hartkloppingen voelde was deze persoon mogelijk ook vaker bang voor een paniekaanval.

Het hoofdstuk beschrijft hoe een ongericht gelijktijdig netwerk, net als het gerichte temporele netwerk, indicatief kan zijn voor mogelijke relaties in een persoon, en zodoende als hypothese-genererend gebruikt kan worden in klinische praktijk. De methoden om een temporeel en gelijktijdig netwerk te schatten op een gering aantal observaties is onder andere geïmplementeerd in het R pakket *graphical-VAR*.⁵ Het hoofdstuk beschrijft twee voorbeelden waarin deze software is gebruikt op data van patiënten, en beschrijft welke klinische inzichten verkregen kunnen worden uit een dergelijke analyse.

C.3 Deel II: Technologische ontwikkelingen in de netwerkpsychometrie

Hoofdstuk 6: Ontdekking van dynamische relaties in psychologische data

In dit hoofdstuk wordt het meest gebruikte netwerkmodel voor continue variabelen, het Gaussisch grafisch model (*Gaussian graphical model*; GGM) geïntroduceerd in de context van het ontdekken van dynamische relaties in psychologische data, wanneer kan worden aangenomen dat de data multivariabel normaal verdeeld zijn. Het GGM is een model voor de inverse van een variantie-covariantie matrix. Het hoofdstuk laat drie equivalenties zien tussen het GGM en andere statistische modellen. Ten eerste kunnen de elementen van de inverse variantie-covariantie matrix gestandaardiseerd worden tot *partiële correlatiecoëfficiënten*. Een netwerk wordt gebruikelijk getekend met partiële correlatiecoëfficiënten als verbindingen. Een partiële correlatie van nul betekent dat twee variabelen conditioneel onafhankelijk zijn en dus elkaar niet direct beïnvloeden. Een partiële correlatie die niet nul is – een verbinding in het netwerk – kan daardoor indicatief zijn van een mogelijk causale relatie. Ten tweede: deze partiële correlatiecoëfficiënten zijn proportioneel aan regressiecoëfficiënten verkregen uit de multipele regressie van één variabele op alle andere variabelen. Dit betekent dat de verbindingen in een GGM netwerk opgevat kunnen worden als predictief, en paden in het netwerken (bijvoorbeeld $A - B - C$) indicatief zijn voor predictieve mediatie. Zodoende brengt het GGM de multicollineariteit van een regressieanalyse in kaart. Ten derde heeft

⁵<https://github.com/SachaEpskamp/graphicalVAR>


het GGM dezelfde vorm als het Ising model, doordat beide lid zijn van een familie van modellen, genaamd Markov willekeurige velden (*Markov random fields*). Deze modellen worden in andere velden van de wetenschap veelvuldig gebruikt om complexe systemen te modelleren (zie hoofdstuk 8).

Wanneer de data niet transversaal zijn (*cross-sectional*; meerdere personen eenmaal gemeten) maar juist bestaan uit meerdere metingen van één of meerdere personen, wordt een algemene assumptie van de statistiek aannemelijk geschonden: opeenvolgende metingen zijn niet onafhankelijk. Zodoende kan het GGM niet zomaar berekend worden op dergelijke data. De tijdserie levert echter ook nieuwe informatie op: hoe variabelen zich tot elkaar verhouden over tijd. In tijdserie-data van een enkel persoon kan rekening gehouden worden met deze schending van onafhankelijkheid door te corrigeren voor het vorige meetmoment. Onder de aanname van multivariabele normaliteit heeft deze correctie de vorm van het vector-autoregressieve model (*vector-autoregression*: VAR). Dit model levert twee netwerken op: (1) een *temporeel netwerk*, een gericht netwerk waarin de voorspellende kracht van een variabele op een andere variabele over de tijd wordt weergegeven, en (2) een *gelijktijdig netwerk*, een GGM berekend op de residuen van de VAR analyse. Beargumenterd wordt, zoals eerder in Hoofdstuk 5, dat beide netwerken relaties vertonen die interessant kunnen zijn voor de onderzoeker. Het temporele netwerk wordt al veelvuldig gebruikt in psychologisch onderzoek omdat het relaties weergeeft die zich over de tijd ontvouwen. Het gelijktijdige netwerk laat daarentegen relaties zien die zich afspelen op een tijdschaal die korter is dan de afstand tussen de metingen.

Wanneer tijdseriedata van meerdere personen beschikbaar zijn, kan er gebruik worden gemaakt van multiniveau (*multi-level*) VAR analyse. In deze analyse kan de grootte van individuele verschillen in kaart worden gebracht. Verder kan onderzocht worden welke relaties *in* een persoon plaatsvinden en welke relaties *tussen* personen plaatsvinden. Dit is een belangrijk verschil met resultaten die verkregen kunnen worden in transversale data. Een transversale relatie tussen bijvoorbeeld moeheid en concentratieproblemen kan voorkomen doordat mensen die over het algemeen moe zijn ook over het algemeen meer concentratieproblemen ervaren (een relatie tussen personen), of omdat wanneer een persoon buitensporig moe is deze persoon ook meer concentratieproblemen ervaart dan zijn of haar gemiddelde (een relatie in een persoon). De multiniveau VAR analyse levert zodoende naast een temporeel en gelijktijdig netwerk per persoon – en schattingen van de populatiegemiddelden: vaste effecten (*fixed effects*) – ook een GGM netwerk op dat de relaties beschrijft tussen de gemiddelde scores van personen: (3) een *tussen-persoons netwerk*. Beargumenterd wordt dat dit tussen-persoons netwerk ook dynamische relaties kan weergeven.

De beschreven multiniveau VAR analyses zijn geïmplementeerd in het R pakket *mlVAR*.⁶ Het hoofdstuk beschrijft simulatieresultaten die laten zien dat *mlVAR* goed de netwerkstructuren kan terugschatten. Figuur C.6 laat een voorbeeld zien van de drie netwerken die verkregen kunnen worden met multiniveau VAR. In deze netwerken zijn variabelen meegenomen die de persoonlijkheidstrek ‘extraversie’ meten en of een persoon inspanning heeft verricht. De resultaten laten zien dat

⁶<https://github.com/SachaEpskamp/mlVAR>




Figuur C.6: Geschatte gemiddelde netwerkstructuren die verkrijgbaar zijn in multiniveau vector-autoregressie. Het model is geschat op basis van 88 mensen die drie tot vijf keer per dag waren gemeten via een smartphone-applicatie; in totaal waren er 3516 observaties. Niet-significante verbindingen zijn verwijderd. Voor de ongerichte netwerken is gebruik gemaakt van de ‘of’-regel voor significantie: een verbinding is behouden als één van de twee regressiecoëfficiënten waarop deze verbinding is gebaseerd significant was. Legenda van knopen: U = ‘uitgaand’; E = ‘energiek’; A = ‘avontuurlijk’; B = ‘blij’; I = ‘inspanning’.

in hetzelfde tijdsblok dat een persoon inspanning verricht (bijv. sporten) deze persoon zich ook gemiddeld meer energiek voelt. In het tijdsblok nadat een persoon inspanning heeft verricht voelt deze persoon zich juist minder energiek. Verder is te zien dat mensen minder uitgaand waren na het verrichten van inspanning. In het tussen-persoons netwerk worden deze relaties niet gevonden. Het tussen-persoons netwerk laat echter een sterke verbinding zien tussen inspanning verrichten en zich avontuurlijk voelen: mensen die zich, over het algemeen, meer avontuurlijk voelen verrichten, over het algemeen, ook meer inspanning. Deze relatie was niet te zien in het temporele netwerk en het gelijktijdige netwerk.

Hoofdstuk 7: Generaliseerde netwerkpsychometrie

In dit hoofdstuk wordt het GGM geïntroduceerd als een formeel psychometrisch model. In een netwerkmodel (Paneel A van Figuur C.7) wordt de samenhang van variabelen gezien als het gevolg van paarsgewijze interacties direct tussen de geobserveerde variabelen. Dit staat in sterk contrast met standaard psychometrie, waarin de samenhang van variabelen juist verklaard wordt door één of meerdere niet geobserveerde (latente) variabelen (Paneel B van Figuur C.7). Dit hoofdstuk beschrijft de relatie tussen het GGM en de meest gebruikte methode voor latente variabelen onderliggend aan continue data: structurele vergelijkmogelijkheidsmodellen (*Structural Equation Modeling*; SEM). Het hoofdstuk laat zien dat netwerkmodellieren de andere kant is van dezelfde munt: waar in SEM de variantie-covariantie wordt gemodelleerd, wordt in het GGM juist de inverse van de variantie-covariantie matrix gemodelleerd. Hierdoor is het GGM direct te implementeren in SEM, en kan van een GGM model passingsmaten worden verkregen of een GGM model vergeleken worden met een SEM model. Door de combinatie



Figuur C.7: Voorbeelden van verschillende mogelijke modellen onder de vier beschreven modelspecificaties. Ronde knopen laten latente variabelen zien, vierkante knopen geobserveerde variabelen en grijze knopen de residuen. Gerichte verbindingen representeren factor-ladingen of regressieparameters en ongerichte verbindingen representeren paarsgewijze interacties. Deze verbindingen zijn *niet* marginale covarianties, maar juist *conditionele*.

van SEM en het GGM ontstaan ook twee nieuwe modellen: latent netwerkmodellen (LNM) en residueel netwerkmodellen (RNM).

Figuur C.7 laat voorbeelden van de twee nieuwe modelspecificaties zien. In Paneel C is een voorbeeld van het LNM model te zien waarin negen geobserveerde variabelen worden verklaard door drie latente variabelen. Op het latente niveau is een ongericht netwerk gemodelleerd in plaats van een gericht netwerk zoals typisch in SEM. Dit netwerk encodeert dat twee latente variabelen onafhankelijk zijn na conditioneren op een derde. Het model in Paneel C is statistisch equivalent aan

het SEM model in Paneel A en heeft geen equivalente modellen (zonder meer latente variabelen toe te voegen). Doordat LNM dergelijke conditionele onafhankelijkheden kan ontdekken, is deze modelspecificatie veelbelovend in exploratief onderzoek naar relaties tussen latente variabelen. Paneel D laat een RNM model zien: een SEM model met een GGM netwerk tussen de residuen. In RNM worden conditionele covarianties gemodelleerd in plaats van marginale covarianties. Hierdoor kan dit model op een spaarzame manier (positief aantal vrijheidsgraden) een residuele variantie-covariantie matrix modelleren waarin geen enkel element nul is. Zodoende wordt in het model van Paneel D geen lokale onafhankelijkheid aangenomen (alle residuen kunnen correleren met elkaar). Deze modelspecificatie is veelbelovend om een confirmatief factor-model passend te maken zonder dat kruisladingen gebruikt moeten worden.

Het hoofdstuk concludeert door te laten zien dat met een bestrafte grootste-aannemelijkheidsschatte, de LASSO, beide modellen kunnen worden geschat. Deze schattingsmethode volgt grofweg de modelselectiemethode beschreven in Hoofdstuk 2. Het gebruik van deze schattingsmethode wordt onderbouwd met twee simulatiestudies. Deze simulatiestudies laten zien dat de methode in combinatie met EBIC modelselectie de ware netwerkstructuur goed kan terugschatten, mits er genoeg observaties zijn. De methoden om deze modellen te schatten zijn geïmplementeerd in het R pakket *lvnet*.⁷

Hoofdstuk 8: Het Ising model in de psychometrie

Dit hoofdstuk introduceert netwerkmodellen voor psychometrici, met een bijzondere nadruk op het netwerkmodel voor binaire data: het Ising model. Het Ising model wordt eerst geïntroduceerd vanuit de statistische natuurkunde, als een model voor magnetisme van deeltjes. Vervolgens laat het hoofdstuk zien dat het Ising model nauw verbonden is aan drie gebruikelijke modellen in de psychometrie: (1) het conditionele Ising model is equivalent aan een logistisch regressiemodel, (2) het Ising model is equivalent aan een loglinear model met hoogstens paarsgewijze interacties, en (3) het Ising model is equivalent aan een bepaald soort latente-variabelenmodel: het multidimensionale item respons theorie (MIRT) model met een conditionele normale verdeling voor de latente trekken.

Met name de laatste equivalentie wordt uitvoerig besproken. Een Ising model is equivalent aan een bepaald soort MIRT model; de rang van de netwerk-matrix komt overeen met het aantal latente variabelen. Zoals eerder beschreven in Hoofdstuk 4 heeft deze equivalentie grote gevolgen voor de interpretatie van netwerkmodellen. Voor elk Ising model bestaat een equivalent latente-variabelenmodel en vice versa. De equivalentie heeft ook gevolgen voor de psychometrie, aangezien het een nieuwe karakterisatie mogelijk maakt van de gezamenlijke verdeling van data gegeven het MIRT model. Het hoofdstuk beschrijft verder hoe het Ising model geschat kan worden en breidt uit over het onderscheiden van netwerkmodellen en latente-variabelenmodellen. Het hoofdstuk beschrijft ten slotte een voorbeeld van geschatte Ising modellen gebruikmakend van het R pakket *elasticIsing*.⁸

⁷<https://github.com/SachaEpskamp/lvnet>

⁸<https://github.com/SachaEpskamp/elasticIsing>

C.4 Deel III: Visualisaties in de psychometrie en persoonlijkheidsonderzoek

Hoofdstuk 9: Visualisering van psychometrische relaties

Dit hoofdstuk introduceert het *qgraph*⁹ pakket voor R in de context van data-visualisatie in de psychometrie. Het *qgraph* pakket kan gebruikt worden voor het weergeven en analyseren van gewogen netwerken, en is de methode die gebruikt is voor de meeste visualisaties in dit proefschrift. Naast de eerder beschreven netwerkmodellen kan *qgraph* gebruikt worden om een netwerk weer te geven van marginale correlatiecoëfficiënten. Op deze manier kan een hoog-dimensionale correlatiematrix op een nieuwe manier worden weergegeven. Deze visualisatiemethode kan inzicht geven in de clustering van variabelen, alsmede in de algemene structuur van correlatieve patronen in de data. Tevens kan met deze visualisatiemethode inzicht gekregen worden in hoe goed een SEM model wel of niet past op de data. Daarnaast kan *qgraph* ook gebruikt worden om andere statistische relaties weer te geven, zoals factor- en componentladingen. Figuur C.8 laat een grafische weergave zien van geschatte componentladingen in een principale-componenten-analyse. Een belangrijk voordeel van deze methode voor het weergeven van factor- of componentladingen is dat er direct inzicht wordt gekregen in zowel de sterkste ladingen als de belangrijkste kruisladingen.

Hoofdstuk 10: De netwerkbenadering in persoonlijkheidsonderzoek

Dit hoofdstuk beschrijft stap voor stap hoe netwerkmodellen in persoonlijkheids-onderzoek kunnen worden gebruikt. Hierbij wordt gebruik gemaakt van regularisatie om een netwerk van partiële correlaties te schatten.¹⁰ Vervolgens beschrijft dit hoofdstuk in detail hoe het verkregen netwerk kan worden geanalyseerd met behulp van centraliteitsmaten, clusteringcoëfficiënten en algemene netwerkeigenschappen. De methode wordt verduidelijkt door data te analyseren van de veelgebruikte HEXACO vragenlijst.


Hoofdstuk 11: Geünificeerde visualisaties van structurele vergelijkingsmodellen

Dit hoofdstuk introduceert het R pakket *semPlot*¹¹, waarmee pad diagrammen kunnen worden gegenereerd op basis van structurele vergelijkingsmodellen (*structural equation modeling*; SEM). Output van verschillende softwarepakketten (zoals *lavaan*, *sem*, *Mplus* en *LISREL*) kunnen worden ingelezen om zodoende een pad diagram te tekenen. Het pakket biedt meer functionaliteit dan alleen pad diagrammen weergeven, en kan tevens gebruikt worden als een brug tussen verschillende

⁹<https://github.com/SachaEpskamp/qgraph>

¹⁰De beschreven methode is vergelijkbaar met de methode die is beschreven in Hoofdstuk 2, die nog niet was geïmplementeerd ten tijde van het schrijven van Hoofdstuk 10

¹¹<https://github.com/SachaEpskamp/semPlot>



Figuur C.8: Visualisatie gemaakt met het *qgraph* pakket van de resultaten van een principale componentanalyse.

softwarepakketten en modelspecificaties. Input voor bijvoorbeeld *lavaan* kan gegenereerd worden op basis van output van bijvoorbeeld *Mplus*. Tevens kunnen de modelmatrices verkregen worden en gebruikt worden voor verdere berekeningen. Het hoofdstuk concludeert met een gedetailleerd overzicht van verschillende algoritmes om de knopen van het pad-diagram te plaatsen.

C.5 Discussie: open vraagstukken in de netwerkpsychometrie

In de tijd van dit promotietraject is de netwerkpsychometrie uitgegroeid tot een veld waarin meer en meer talentvolle onderzoekers hun intrede doen. Hoewel het gebruik van netwerken in de psychologie steeds beter begrepen is en steeds

meer methoden worden ontwikkeld, zijn er ook nog veel open vragen. Derhalve concludeert dit proefschrift met enkele richtingen voor vervolgonderzoek:

1. Er zijn op dit moment weinig manieren om om te gaan met ontbrekende data in het schatten van psychologische netwerken. Meestal worden alle observaties waarin minstens één response ontbreekt volledig weggehaald. Hierdoor worden echter niet alle data meegenomen in de analyse en wordt er een sterke aanname gedaan over de oorzaak waarom een response ontbreekt. De psychometrie kent een lange geschiedenis van omgaan met ontbrekende data, waar de literatuur van het schatten van netwerkmodellen veel van kan leren.
2. Veel data in de psychologie zijn gemeten op een ordinale schaal. Bijvoorbeeld, veel vragenlijsten in de psychopathologie meten de ernst van symptomen op een schaal van 0 (geen klachten) tot 3 (heel veel klachten). De psychometrie kent ook hier een lange geschiedenis van het modelleren van dergelijke data. Dit soort data komt echter niet voor in de velden waarin netwerkmodellen doorgaans worden gebruikt. Derhalve is het gebruik van ordinale data in het schatten van netwerkmodellen nog niet goed uitgewerkt. De doorgaans gebruikte methodes – het gebruik van polychorische correlaties voor het berekenen van een netwerk van partiële correlaties of het discreet maken van antwoorden om vervolgens een Ising model te berekenen – zijn niet zonder problemen. Het is dus van cruciaal belang dat het modelleren van ordinale data in netwerkmodellen verder wordt ontwikkeld.
3. Zoals beschreven in Hoofdstuk 4 is het momenteel niet mogelijk evidentie te vinden dat het ware netwerk spaarzaam is (niet alle knopen zijn verbonden). Dit terwijl het ontbreken van verbindingen een belangrijke interpretatie met zich mee brengt: conditionele onafhankelijkheid. Derhalve is het van belang dat methoden worden ontwikkeld die wel evidentie kunnen vergaren voor het ontbreken van verbindingen. Veelbelovend hierin is het gebruik van Bayesiaanse statistiek, waarin de Bayes-factor een steeds meer gebruikte maat is die evidentie voor een null-hypothese kan vergaren. Toekomstig onderzoek zou zich kunnen richten op het ontwikkelen van standaard Bayesiaanse testen voor netwerkverbindingen.
4. Vaak worden de verkregen netwerkstructuren geanalyseerd op een vergelijkbare manier als bijvoorbeeld wegen-netwerken of sociale netwerken. De modellen die voor dit proefschrift zijn gebruikt, zijn echter structureel anders. De knopen representeren variabelen met meerdere staten en de verbindingen representeren statistische relaties. Deze modellen worden *probabilistische grafische modellen* genoemd en encoderen de volledige gezamenlijke verdeling van een set variabelen. Het is de vraag of dergelijke modellen wel moeten worden geanalyseerd met maten uit de grafentheorie. De discussie laat zien dat met gebruik van informatietheorie op een andere manier gekeken kan worden naar de verkregen resultaten. Meer onderzoek is nodig om deze maten te valideren.
5. De netwerkmodellen die zijn gepresenteerd in dit proefschrift modelleren alleen de samenhang van variabelen. Er wordt in deze netwerken niet gekeken

naar de drempelwaarde van een variabele (bijv. dat het symptoom ‘suïcidale gedachten’ minder vaak voorkomt dan het symptoom ‘droevige stemming’). Deze eigenschap wordt gemodelleerd met een intercept. Doordat niet gekeken wordt naar intercepten kan het zijn dat twee variabelen aan elkaar worden verbonden zonder dat deze vergelijkbaar zijn in drempelwaarde. Dit kan problematisch zijn. Mogelijk kan vervolgonderzoek kijken naar het construeren van netwerken waarbij ook het intercept een rol speelt.

Het proefschrift concludeert met de notie dat de beschreven netwerkmodellen, hoewel veelbelovend, lang niet de enige methode vormen om om te gaan met de meer algemenere hypothese dat psychologie complex is. De toekomst zal uitwijzen welke plek deze methoden in psychologisch onderzoek zullen innemen.