

Casper Albers

Psychometrie & Statistiek
Rijksuniversiteit Groningen
c.j.albers@rug.nl

Psychologische netwerken – Een introductie

De afgelopen tien jaar is het gebruik van netwerkmodellen voor psychologische datasets enorm toegenomen. In dit artikel legt Casper Albers de achtergrond van deze modellen uit.

Meten is weten. In medisch onderzoek wordt veelvuldig gebruik gemaakt van meetinstrumenten om bijvoorbeeld de hartslag te meten of om te tellen hoeveel tumormarkers er in het bloed zitten. Hier is vaak ingewikkelde technologie voor nodig, maar de statistiek is redelijk eenvoudig: je meet wat je wilt meten, met daaroverheen een (doorgaans) normaalverdeelde meetfout.

In de klinische psychologie ligt dit anders. Ziektes als angststoornissen of depressies laten zich niet direct meten: er is geen apparaat dat, na analyse van een druppeltje bloed of urine, iemands depressiescore op een schaal van 0 tot 100 uitrekent. Bepalen of iemand klinisch depressief is, gebeurt door te kij-

ken naar de aanwezigheid en ernst van symptomen.

De *Diagnostic and Statistical Manual of Mental Disorders* (DSM-V) geeft de richtlijnen weer waarop psychische aandoeningen gescoord worden. Zo spreekt men (kort door de bocht samengevat) van klinische depressie wanneer minstens vijf van de volgende negen symptomen met grote regelmaat voorkomen: (1) depressieve gedachten, (2) verminderd plezier in de meeste activiteiten, (3) significante verandering in eetlust of gewicht, (4) slapeloosheid of juist overmatige vermoeidheid, (5) rusteloosheid of andere activiteitsproblemen, (6) gebrek aan energie, (7) gevoel van waardeloosheid, (8) concentratieproblemen, en (9) suïcidale gedachten.

Momentary assessment

Veel psychologische meetgegevens worden verzameld via vragenlijsten. Door technologische vooruitgang is het mogelijk om dergelijke vragenlijsten met regelmaat af te nemen, bijvoorbeeld met een app op de smartphone. Deze manier van dataverzameling wordt *ecological momentary assessment* [25] genoemd: doordat je 'live' aan iemand kan vragen hoe het op dat moment gaat, is de ecologische validiteit van de meting hoger dan wanneer je achteraf een mening over bijvoorbeeld de afgelopen week vraagt. Niet alleen is de ecologische validiteit hoger: je krijgt ook meer inzicht in iemands gemoedstoestand wanneer je deze persoon over een bepaalde periode monitort. Niemands emotionele gesteldheid is namelijk constant: je zit het ene moment wat beter in je vel dan het andere. Ook volgens de spelregels van de


DSM-V moet je minimaal gedurende een periode van twee weken vijf van de bovengenoemde negen symptomen hebben; een enkele slapeloze nacht is nog geen depressie.

Om goed de processen die ten grondslag aan menselijk gedrag liggen te begrijpen, is het dus van vitaal belang om dezelfde variabelen bij dezelfde personen met grote regelmaat te meten. Dit is nodig om inzicht te verkrijgen in de gecompliceerde aspecten van menselijk gedrag. Die complexiteit uit zich door fluctuaties in gedrag over de tijd. Deze fluctuaties hangen af van de context, van inter-individuele verschillen, en van toevallige verstoringen. Het begrijpen van de dynamiek van een psychologisch proces is een essentiële voorwaarde om het proces zelf te begrijpen [1].

De klassieke aanpak

Traditioneel worden dergelijke zaken aangepakt met een latente variabelen-model [21]. Een latente variabele is een variabele die je niet zelf kan meten, maar waarvan je de waarde voorspelt aan de hand van observeerbare variabelen. Een voorbeeld is gegeven in Figuur 1. Op basis van de gemeten uitkomsten x_1, \dots, x_k wordt de latente variabele y samengesteld als gewogen som van de symptomen: $y = \sum a_i x_i$. Hierbij wordt gebruikgemaakt van factoranalyse.

Recentelijk is men afgestapt van deze gedachtenlijn. Pogingen binnen de psychopathologie om psychische aandoeningen terug te brengen tot eendimensionale (biologische) constructen, zijn mislukt [18]. De nieuwe gedachtenlijn is dat we bij psychische stoornissen de symptomen niet moeten zien als *gevolg* van de aandoening, maar als de aandoening zelf: die structurele slapeloosheid, gebrek aan eetlust en terugkerende suïcidale gedachten, dat *is*



Figuur 1 Voorbeeld van een latente variabelen-diagram met drie geobserveerde en een latente variabele.


de depressie. Er is niet een of andere gehypothetiseerde latente variabele ‘depressie’, de depressie dat is wat je waarneemt.

Psychologische netwerktheorie


Deze gedachtenlijn, ingebracht door een groep psychometrici van de Universiteit van Amsterdam [5,7], leidt op een natuurlijke manier tot de netwerkmodellen zoals die nu binnen de psychopathologie en klinische psychologie gebruikt worden. In Figuur 2 wordt zo’n netwerk, gebaseerd op drie variabelen, weergegeven. Afhankelijk van wat voor type data verzameld is – meerdere personen op een tijdstip, of een persoon over meerdere tijdstippen – kunnen de zijden van het netwerk een richting hebben of niet. Figuur 2 maakt gebruik van zijden met een richting; hoe dikker de zijde, hoe groter het effect. Een hoge score op variabele 1 op het ene tijdstip correleert dus flink met een hoge score op diezelfde variabele het volgende tijdstip, maar slechts licht met een hoge score op variabele 2 op het volgende tijdstip. Zouden niet meerdere tijdstippen maar meerdere personen (eenmalig) gemeten zijn, dan geeft de dikte van de zijden aan hoe sterk variabelen met elkaar correleren tussen personen.

De steeds groter wordende onderzoeksgroepen en datasets hebben ertoe geleid dat klinisch psychologen meerdere aandoeningen simultaan willen onderzoeken. Doorgaans staan aandoeningen niet compleet los van elkaar, maar zijn er overlappende symptomen. In Figuur 3 worden twee aandoeningen beschouwd: de ene aandoening bestaat uit variabelen 1, 2 en 3; de ander uit 3, 4 en 5. Variabele 3 slaat een brug tussen beide aandoeningen en wordt derhalve een *bridge variable* genoemd.

De brugvariabelen tussen klinische depressie en een angststoornis zijn de symptomen slapeloosheid, vermoeidheid en concentratieproblemen [5]. Dit is relevant bij de behandeling van patiënten met ofwel depressie ofwel angststoornissen: het is een bekend gegeven uit de literatuur dat de behandeling van meerdere stoornissen tegelijk – comorbiditeit geheten – veel ingewikkelder is dan de behandeling van een enkele stoornis. Het geheel is meer dan de som der delen, wat hier dus een nadelig effect heeft. De behandeling van een psychische stoornis gebeurt vaak door het tegengaan van een of meerdere symptomen, en in dit geval



Figuur 2 Voorbeeld van een netwerkdiagram met drie variabelen.



Figuur 3 Voorbeeld van een ‘bridge variable’, variabele 3.

wordt er voorrang verleend aan het tegengaan van slapeloosheid, vermoeidheid en concentratieproblemen, omdat dit de brugvariabelen zijn.

Brugvariabelen zijn bij niet-psychologische netwerken vaak makkelijker te conceptualiseren. Denk bijvoorbeeld aan het netwerk van NS treinstations. Al het verkeer vanuit Groningen, Friesland en Drenthe naar bijvoorbeeld de Randstad moet via station Zwolle: er is geen andere route. Zwolle is daarmee de brugvariabele tussen het westen en het noorden. Wanneer er problemen zijn op station Zwolle, heeft dat direct invloed op al het treinverkeer van het westen naar het noorden en vice versa. Andere stations vervullen die rol veel minder. Als er vanwege spoorproblemen geen treinen langs Zoetermeer kunnen, is dat uiterst vervelend voor degenen met Zoetermeer als beginpunt of eindpunt van de reis. Maar reizigers van bijvoorbeeld Den Haag naar Utrecht kunnen met minieme vertraging omrijden via Leiden. Iets soortgelijks speelt dus bij de symptomen van psychologische aandoeningen.

Het Gaussische Grafische Model (GGM)

Voor een groot deel is de psychologische netwerktheorie nieuwe wijn in oude zakken. Het onderliggende netwerkmodel is namelijk niet nieuw; het is de methodologische manier van denken over psychische aandoeningen die nieuw is.

Het meestgebruikte netwerkmodel binnen de psychologische toepassingen is het Gaussische Grafische Model (GGM). Dit model werd in de jaren zeventig geïntroduceerd [8] en sindsdien veelvuldig toegepast. Het boek *Graphical Models* van de Deense statisticus Steffen Lauritzen [20] geldt als hét naslagwerk voor GGMs. Binnen de sociale wetenschappen, worden GGMs, en andere netwerkmodellen, al enkele decennia succesvol toegepast bij sociale netwerkanalyse [9,24], maar dus pas sinds een jaar of tien voor psychologische netwerken.

Het standaard GGM, zonder tijdsdimensie, werkt als volgt. Gegeven is een $n \times p$ datamatrix X : p variabelen zijn n keer gemeten. De eerste letter G uit het GGM verwijst naar de aanname van normaliteit van de data:

$$X \sim N(\mu, \Sigma).$$

Neem als voorbeeld een dataset waarbij van $n = 88$ studenten de cijfers op vijf wiskundevakken gemeten is [23]. Doel van een netwerkmodel is om verbanden, correlaties dus, te visualiseren. Tabel 1 laat de Pearson product-momentcorrelaties tussen de vijf vakken zien. Alle vakken hebben een positieve samenhang, met correlaties van 0,39 tot 0,71. In Tabel 1 zijn er $5 \times 4/2 = 10$ unieke correlaties en dit is nog enigszins overzichtelijk. Wanneer je met grotere datasets werkt, stijgt dit aantal snel: bij p va-

	mec	vec	alg	ana	sta
mechanica	1,00	0,55	0,55	0,41	0,39
vectoralgebra	0,55	1,00	0,61	0,48	0,44
algebra	0,55	0,61	1,00	0,71	0,66
analyse	0,41	0,48	0,71	1,00	0,61
statistiek	0,39	0,44	0,66	0,61	1,00

Tabel 1 Correlaties tussen de cijfers van $n = 88$ studenten op vijf wiskundevakken [23].


riabelen heb je $p(p-1)/2$ correlaties (en, als er een tijdsdimensie aanwezig is zelfs p^2 unieke variabelen) en dan is niet meer (makkelijk) te zien waar de sterke verbanden zitten. De meerwaarde van de GGM ligt met name in het visualiseren van de verbanden.

Figuur 4(a) laat zo'n visualisatie zien. Elke variabele wordt weergegeven door een node (een cirkel) en de correlatie tussen twee variabelen, een zijde (lijnstuk tussen beide variabelen): een groene zijde voor een positief verband en een rode bij eventuele negatieve verbanden. De dikte van de zijde is proportioneel met de correlatie. De geschatte correlatiematrix, $\hat{\Sigma}$, geeft dus direct de informatie die nodig is voor de visualisatie. In een oogopslag is te zien dat de vakken statistiek, analyse en algebra onderling de sterkste samenhang hebben.

Nadeel van Figuur 4(a) is dat elke variabele wel samenhang vertoont met elke andere. Dit is bij psychologische datasets niet anders. Dat bij de symptomen van klinische depressie slapeloosheid, gebrek aan energie en concentratieproblemen sterk samenhangen is evident. Het is informatiever om de *partiële* correlaties, gegeven door $\hat{\Sigma}^{-1}$ te visualiseren; zie

Figuur 4(b). Een groot voordeel van het werken met partiële correlaties bij normaalverdeelde data is dat de grafiek nu conditionele onafhankelijkheid laat zien. Zo is de partiële correlatie tussen statistiek en vectoralgebra (nagenoeg) nul, wat impliceert dat de scores op deze vakken (nagenoeg) onafhankelijk zijn, conditioneel op de andere vakken. Oftewel: als je van een student de cijfers op analyse, algebra en mechanica weet, biedt het geen meerwaarde meer om het statistiekcijfer te kennen wanneer je het vectoralgebra-cijfer wilt voorspellen.

Het is wenselijk om het aantal zichtbare zijdes nog verder terug te brengen: als een (partiële) correlatie te dicht bij nul ligt, is deze toch niet praktisch relevant. Dit terugbrengen kan op twee manieren: via *thresholding* en via de *graphical lasso*-methode. Bij thresholding zet je simpelweg alle correlaties waarvoor geldt dat $|r| < \theta$, met θ bijvoorbeeld 0,2, gelijk aan nul. Bij de graphical lasso-methode (GLASSO [16]) wordt de partiële correlatiematrix geschat onder L_1 -penalties. De waarden dicht bij nul worden daardoor richting nul getrokken, en de overige waarden worden geschat conditioneel op die nulwaarden. Met een tuning-parameter kan je instellen hoe



Figuur 4 Netwerken gebaseerd op de gegevens van Tabel 1: (a) Correlatie-netwerk, (b) Partiële correlatie-netwerk, (c) GLASSO-netwerk.

sterk de L_1 -penalty moet optreden. Zoals te zien in Figuur 4(c) levert dit een duidelijkere visualisatie op.

Gerelateerd aan het concept van brugvariabelen is centraliteit. Met centraliteitsmethoden wordt gekeken welke variabelen het belangrijkst zijn. De meestgebruikte centraliteitsmaat is die van ‘node strength’, gedefinieerd als de som van alle absolute waarden van de zijden van/naar een node. In Figuur 4(c) heeft algebra de hoogste en mechanica de laagste centraliteit. Hoewel gebruikt binnen de psychologie, zijn er kritische stemmen over de interpretatie van centraliteit in een klinisch psychologische context [6].

Netwerken voor tijdreeksdata

In de vorige paragraaf ging het over netwerken voor data met per persoon eenmalig een meting. Het is voor psychologisch onderzoek, zoals omschreven onder het kopje ‘Momentary assessment’, juist interessant om iemand meerdere keren over de tijd te meten. In principe krijg je zo nog steeds een datamatrix X van afmeting $n \times p$, alleen bestaat de i -de rij nu niet uit de data van persoon i maar van tijdstip i . Via een tijdreeksmodel is dan te beschouwen hoe de metingen op tijdstip i afhangen van die op tijdstip $i - 1$. Hiervoor wordt meestal het vector autoregressieve model van de eerste orde (VAR(1)) gebruikt:

$$X_i = BX_{i-1} + \varepsilon_i.$$

Hierin is B een matrix van regressiegewichten waarbij B_{ab} aangeeft hoe de meting van variabele a afhangt van de waarde van variabele b op het vorige moment. Om de link met conditionele onafhankelijkheid te bewaren, wordt van de residuen ε aangenomen dat ze onderling onafhankelijk zijn en een $N(0, \Sigma_\varepsilon)$ -verdeling volgen.

Net als bij het niet-tijdsafhankelijke GGM is het hier gebruikelijk om via L_1 -penalties het aantal zijden laag te houden. Het meestgebruikte algoritme hiervoor [26] zit ingebouwd in de standaard packages in R voor dit soort analyses [10, 11]. Figuur 2 is een voorbeeld van het soort visualisatie dat dit oplevert.

‘Klassiek’ versus psychologisch

Zoals gezegd zijn psychologische netwerken sterk gebaseerd op andere netwerkmodellen. Ze hebben echter ook een aantal methodologische eigenschappen die ze uniek maken.

1. Psychologische netwerken zijn netwerken van *variabelen*, bij andere modellen zijn de nodes ‘dingen’. Bij het eerder genoemde NS-netwerk waren de nodes treinstations: deze zijn statisch. Ook bij sociale netwerken zijn de nodes statische entiteiten, bijvoorbeeld personen.
2. Die modellen kunnen worden uitgebreid door bijvoorbeeld op een bepaald moment een persoon toe te voegen of weg te halen uit het model; maar bij psychologische netwerken zijn de nodes — slapeloosheid, concentratieproblemen, et cetera — per definitie variabel. De nodes in een psychologisch netwerk zijn dus toevalsvariabelen, in andere modellen is dit niet zo.
3. De zijden in een niet-psychologisch netwerk kunnen geobserveerd worden: de treinstations waartussen een trein rijdt, zijn verbonden; de personen die elkaars Facebook-vrienden zijn, zijn verbonden, enzovoort. Bij psychologische netwerken dienen de zijden geschat te worden en bevatten dus statistische onzekerheden. Denk bijvoorbeeld aan de correlatie tussen vakken: bij een andere steekproef zouden we andere correlaties gemeten hebben.
4. Bij psychologische netwerken is het hoofddoel om te laten zien welke nodes tegelijk optreden. Bij niet-psychologische netwerken is het hoofddoel om de aanwezigheid/afwezigheid van zijden te bepalen, de meest centrale node te vinden, enzovoort.

Schaalvalidatie

Psychologische netwerken kunnen niet alleen gebruikt worden als vervanger van de latente variabelen-modellen; maar ook als vervanger van de schaalvalidatie-technieken uit de klassieke psychometrie. Psychologische vragenlijsten bestaan doorgaans uit meerdere vragen die hetzelfde concept meten. Via instrumenten als Cronbachs alfa is vervolgens te meten of er niet een vraag is die duidelijk afwijkt van de rest.

Dit kan ook via een netwerkvisualisatie. In [3] laten we zien hoe dit moet. Een uitgebreide vragenlijst met 65 vragen in 22 domeinen is afgenomen onder 694 deelnemers. Een netwerkvisualisatie van alle 65 vragen laat duidelijk zien dat de vragen uit hetzelfde domein dichter bij elkaar liggen dan bij vragen uit andere domeinen: aan een van de voorwaarden voor een valide meetschaal is daarmee voldaan.

Vergelijken/samenvoegen van netwerken

Psychologische netwerken worden, zeker bij *single case designs*, vaak vooral gebruikt voor exploratieve doeleinden. Het is echter goed mogelijk om ook confirmatieve conclusies te trekken. Via bootstrapmethoden kan worden gekeken of bepaalde zijden significant afwijken van nul of van andere zijden en welke nodes een significante centraliteitsmaat hebben [12]. Soms wil men ook verschillende netwerken met elkaar vergelijken: bijvoorbeeld de netwerken van een groep personen gediagnosticeerd met klinische depressie en die van een groep zonder die diagnose. Zijn de netwerken daadwerkelijk verschillend of zijn de visuele verschillen het resultaat van toeval? Voor zulke vergelijkingen is de Network Comparison Test [4] geschikt. Deze test is gebaseerd op de Manteltest [22] om een tweetal correlatiematrixen te vergelijken.

Men kan ook proberen de netwerken van verschillende personen samen te voegen. Een manier om dit te doen is met behulp van multilevel-modellen, ook bekend als hiërarchische modellen [13]. Bij dergelijke modellen is het model voor individu k gegeven door

$$X_i^{(i)} = B^{(k)} X_{i-1} + \varepsilon_i^{(k)}$$

met

$$B^{(i)} \sim N(B, \Sigma_B) \text{ en } \varepsilon_i^{(k)} \sim N(0, \Sigma_\varepsilon).$$

Een andere aanpak is het gebruik van clusteringtechnieken. Hierbij worden personen met gelijksoortige karakteristieken in eenzelfde cluster gezet. Dit kan of in een tweestapsmodel, waarbij eerst de individuele karakteristieken worden bepaald en deze daarna worden geclusterd [19]. Het kan echter ook in een geïntegreerd model waarbij beide stappen simultaan gezet worden [14].

Verder lezen

De afgelopen pagina’s heb ik geprobeerd een korte introductie te geven van de psychologische netwerktheorie. De geïnteresseerde lezer kan uit een breed scala aan literatuur kiezen om meer te lezen. Het boek van Lauritzen [20] bevat alle (wiskundige) achtergrond voor GGM’s. Psychologische netwerken worden uitgelegd in verschillende artikelen [3, 12, 17] en websites [15].

Referenties

- 1 Albers, C.J. (2019), Toegepaste statistiek: van ontwikkeling tot communicatie, Oratie, Rijksuniversiteit Groningen, *Nieuw Archief voor Wiskunde* 5/20(2), 94–100.
- 2 American Psychiatric Association (2013), *Diagnostic and Statistical Manual of Mental Disorders* (vijfde editie).
- 3 Bhushan, N., Mohnert, F., Sloot, D., Jans, L., Albers, C.J. en Steg, L. (2019), Using a Gaussian Graphical Model to Explore Relationships Between Items and Variables in Environmental Psychology Research, *Frontiers in Psychology* 10, 1050.
- 4 Borkulo, C.D. van, Waldorp, L.J., Boschloo, L., Kossakowski, J., Tio, P., Schoevers, R. en Borsboom, D. (2016), Comparing network structures on three aspects: A permutation test, Preprint op ResearchGate.
- 5 Borsboom, D. en Cramer, A.O.J. (2013), Network analysis: an integrative approach to the structure of psychopathology, *Annual Review of Clinical Psychology* 9, 91–121.
- 6 Bringmann, L.F., Elmer, T., Epskamp, S., Krause, R.W., Schoch, D., Wichers, M., Wigman, J. en Snippe, E. (2018), What do centrality measures measure in psychological networks? Te verschijnen in *Journal of Abnormal Psychology*.
- 7 Cramer, A.O.J., Waldorp, L., Maas, H. van der en Borsboom, D. (2010), Comorbidity: A network perspective, *Behavioral and Brain Sciences* 33(2–3), 137–150.
- 8 Dempster, A.P. (1972), Covariance selection, *Biometrics* 28(1), 157–175.
- 9 Duijn, M.A. van en Vermunt, J.K. (2006), What is special about social network analysis? *Methodology* 2(1), 2–6.
- 10 Epskamp, S., Cramer, A.O.J., Waldorp, L.J., Schmittmann, V.D. en Borsboom, D. (2012), qgraph: Network visualizations of relationships in psychometric data, *Journal of Statistical Software* 48(4), 1–18.
- 11 Epskamp, S. (2018), graphicalVAR: Graphical VAR for experience sampling data, <https://CRAN.R-project.org/package=graphicalVAR>.
- 12 Epskamp, S., Borsboom, D. en Fried, E. (2018), Estimating psychological networks and their accuracy: a tutorial paper, *Behavioural Research Methods* 50(1), 195–212.
- 13 Epskamp, S., Waldorp, L.J., Möttus, R. en Borsboom, D. (2018), The Gaussian graphical model in cross-sectional and time-series data, *Multivariate Behavioral Research* 53(4), 453–480.
- 14 Ernst, A.F., Timmerman, M.E., Jeronimus, B. en Albers, C.J. (2019), Inter-individual differences in multivariate time series: dynamic adaptive cluster modelling based on finite mixtures of vector-autoregressive processes. Ingestuurd voor publicatie.
- 15 Fried, E.I. (2019), Psych networks website, <https://psych-networks.com/tutorials>.
- 16 Friedman, J., Hastie, T. en Tibshirani, R. (2008), Sparse inverse covariance estimation with the graphical lasso, *Biostatistics* 9(3), 432–441.
- 17 Jones, P.J., Mair, P. en McNally, R.J. (2018), Visualizing psychological networks: a tutorial in R, *Frontiers in Psychology* 10, 3389.
- 18 Kendler, K.S. (2005), Toward a philosophical structure for psychiatry, *American Journal of Psychiatry* 162, 433–440.
- 19 Krone, T., Albers, C.J., Kuppens, P. en Timmerman, M.E. (2017), A multivariate statistical model for emotion dynamics, *Emotion* 18(5), 739–754.
- 20 Lauritzen, S.L. (1996), *Graphical Models*, Clarendon Press.
- 21 Loehlin, J.C. (2004), *Latent Variable Models. An Introduction to Factor, Path and Structural Equation Analysis* (vierde editie), Psychology Press.
- 22 Mantel, N. (1967), The detection of disease clustering and a generalized regression approach, *Cancer Research* 27(2).
- 23 Mardia, K.V., Kent, J.T. en Bibby, J.M. (1979), *Multivariate Analysis*, Academic Press.
- 24 Scott, J. (1988), Social network analysis, *Sociology* 22(1), 109–127.
- 25 Shiffman, S., Stone, A.A. en Hufford, M.R. (2008), Ecological momentary assessment, *Annual Review of Clinical Psychology* 4, 1–32.
- 26 Wild, B., Eichler, M., Friederich, H.C., Hartmann, M., Zipfel, S. en Herzog, W. (2010), A graphical vector autoregressive modelling approach to the analysis of electronic diary data, *BMC Medical Research Methodology*, 10(1), 28.