

University of Groningen

## Some notes on Bayesian time series analysis in psychology

Krone, Tanja

**IMPORTANT NOTE: You are advised to consult the publisher's version (publisher's PDF) if you wish to cite from it. Please check the document version below.**

*Document Version*

Publisher's PDF, also known as Version of record

*Publication date:*

2016

[Link to publication in University of Groningen/UMCG research database](#)

*Citation for published version (APA):*

Krone, T. (2016). *Some notes on Bayesian time series analysis in psychology*. [Groningen]: Rijksuniversiteit Groningen.

### Copyright

Other than for strictly personal use, it is not permitted to download or to forward/distribute the text or part of it without the consent of the author(s) and/or copyright holder(s), unless the work is under an open content license (like Creative Commons).

### Take-down policy

If you believe that this document breaches copyright please contact us providing details, and we will remove access to the work immediately and investigate your claim.

*Downloaded from the University of Groningen/UMCG research database (Pure): <http://www.rug.nl/research/portal>. For technical reasons the number of authors shown on this cover page is limited to 10 maximum.*

# Samenvatting

In mijn proefschrift richt ik mij op het gebruik van tijdsreeksanalyse in psychologisch onderzoek. Ik focus hierbij op twee aspecten. Ten eerste onderzoek ik het effect van verschillende schatters en data-eigenschappen op het schatten van de autocorrelatie. Dit gebeurt in Hoofdstuk 2 en 3. Ten tweede bestudeer ik de uitdagingen van empirische data-analyse en hoe de link gelegd kan worden tussen psychologische theorieën en de statistische modellen. Dit gebeurt in Hoofdstuk 4, 5 en 6. Voor het tweede aspect gebruik ik het Bayesiaanse dynamische model, dat alle uitdagingen aankon die ik vond in de empirische datasets die ik heb geanalyseerd.

In **Hoofdstuk 2** bespreek ik verschillende schatters van het autoregressieve model voor univariate data. Ik vergelijk hun prestaties bij het schatten van de autocorrelatie in korte tijdsreeksen. In Studie 1, onder correcte modelspecificatie, vergelijk ik de frequentistische  $r_1$ , C-schatter, de ordinary least squares (OLS) schatter en de maximum likelihood estimator (MLE), alsmede een Bayesiaanse schattingsmethode met een platte prior ( $B_f$ ), dan wel de zogenaamde symmetrized reference prior ( $B_{sr}$ ). In een compleet gekruist onderzoeksontwerp varieer ik de lengte van de tijdsreeks (d.w.z.,  $T = 10, 25, 40, 50$  en  $100$ ) en de autocorrelatie (van  $-0.90$  tot  $0.90$  met stappen van  $0.10$ ). De resultaten laten zien dat de kleinste bias (vertekening) wordt gevonden voor  $B_{sr}$  en de laagste variabiliteit voor  $r_1$ . In de verschillende condities is de power (het onderscheidingsvermogen) het grootst voor  $B_{sr}$  en OLS. Voor  $T = 10$  presteren, zoals verwacht, alle schatters slecht. In Studie 2 bestudeer ik de robuustheid van twee van de schatters aan de hand van een misspecificatie. In deze studie wordt de data gegenereerd met behulp van een ARMA(1,1) model, maar geanalyseerd met een AR(1) model. Hiervoor gebruik ik de twee methoden met de laagste bias in de eerste studie, d.w.z.,  $B_{sr}$  en MLE. De bias wordt groter wanneer de ongemodelleerde autocorrelatieparameter van de ruis groter wordt. Zowel de variabiliteit als de power zijn afhankelijk van deze ongemodelleerde parameter. De verschillen tussen de MLE en  $B_{sr}$  zijn te verwaarlozen voor alle gebruikte uitkomstmaten.

In **Hoofdstuk 3** schat ik tijdsreeksmodellen voor meerdere individuen met behulp van multilevel modellen. Ik vergelijk hierbij twee schattingsmethoden voor de

autocorrelatie in multilevel AR(1) modellen, namelijk MLE en Bayesiaanse Markov Chain Monte Carlo, eerder  $B_{sr}$  genoemd. Verder bestudeer ik de verschillen tussen het modelleren van zogenaamde random en fixed individuele parameters. Om dit te bereiken voer ik een simulatiestudie uit met een volledig gekruist onderzoeksontwerp, waarbij ik de lengte van de tijdsreeksen (10 of 25) en de hoeveelheid individuen in de datasets (10 of 25) varieer, alsmede het gemiddelde ( $-0.60$  tot  $0.60$  in stappen van  $0.30$ ) en de standaarddeviatie ( $0.25$  of  $0.40$ ) van de verdeling waaronder ik de autocorrelatie genereer. De random schatters van de gemiddelde autocorrelatie in de populatie laten een kleinere bias en hogere power zien dan de fixed schatters. Zoals verwacht profiteren de random schatters sterk van een toegenomen aantal individuen, maar is dit effect klein voor de fixed schatters. De fixed schatters hebben iets meer voordeel van een toegenomen aantal tijdspunten dan de random schatters. Gelet op de hogere power en kleinere bias, wordt waar mogelijk het random schatten van de parameters geprefereerd boven het fixed schatten. Het verschil tussen de MLE en de  $B_{sr}$  is bijna verwaarloosbaar. De  $B_{sr}$  heeft een kleinere bias, maar MLE heeft een kleinere variabiliteit (i.e., de standaarddeviatie van de parameter schattingen). Er worden betere resultaten gevonden wanneer er meer individuen en tijdspunten zijn, evenals voor een kleine standaarddeviatie van de autocorrelatie. Het effect van het gemiddelde van de autocorrelatie is afhankelijk van de gebruikte uitkomstmaat.

In **Hoofdstuk 4** gebruik ik het Bayesiaanse dynamische model (BDM) om verschillende modelvarianten te vergelijken voor een univariate dataset bestaande uit metingen van meerdere individuen. Deze dataset vertoont verschillende uitdagingen, zoals ontbrekende scores en niet-normaal verdeelde residuen. Deze complexe structuur geef ik weer met een hiërarchisch BDM. Het BDM is een gegeneraliseerd lineair hiërarchisch model waar de individuele parameters niet per se een normale verdeling volgen. Het model kan geschat worden op basis van een relatief kleine dataset met ontbrekende scores. Ik presenteer het BDM en bespreek de modelidentificatie, convergentie en selectie. Het gebruik van het BDM illustreer ik aan de hand van data van een gerandomiseerde klinische proef, opgezet om het verschil in effect van drie behandelingen tegen paniekstoornissen te bestuderen. De data bestaan uit de hoeveelheid paniekaanvallen die wekelijks ervaren worden (73 individuen, 10 tot 52 datapunten per individu) tijdens de behandeling. Onder de aanname dat de scores een Poissonverdeling volgen, wordt er een model gebruikt met een lineaire trend en een exponentiele link functie. Het uiteindelijke model bevat ook een autocorrelatiecoëfficiënt voor de ruis en een externe variabele (tijdsduur van de symptomen voor de behandeling). Onze resultaten laten zien dat cognitieve gedragstherapie minder effectief is dan het gebruik van selectieve serotonine-heropnameremmers of een combinatie van beide in het verminderen van het aantal ervaren paniekaanvallen per week. Post-hoc analyses laten zien dat mannen een licht hoger aantal paniekaanvallen hebben aan het begin van de

behandeling vergeleken met vrouwen.

In **Hoofdstuk 5** gebruik ik het BDM om een multivariate dataset met emotiedata van meerdere individuen met ontbrekende scores te analyseren. Onderzoek naar emotiedynamiek richt zich over het algemeen op het onthullen van informatie over het functioneren en reguleren van emoties en affect. Hierbij worden verschillende elementaire eigenschappen van de emotiedynamiek onderscheiden, die worden bestudeerd met behulp van intensieve longitudinale data. Over het algemeen wordt elk van deze eigenschappen apart gekwantificeerd, wat het bestuderen van de onderlinge relaties tussen deze eigenschappen bemoeilijkt. Dit, op zijn beurt, bemoeilijkt de validatie van de theorieën over deze onderlinge relaties. In emotieonderzoek is de lengte van de geobserveerde tijdsreeksen beperkt en is er vaak sprake van veel ontbrekende scores. In dit hoofdstuk gebruik ik een Bayesiaans vector autoregressief model, een variant van het BDM, dat gebruikt kan worden in het onderzoek naar de dynamiek van emoties. Het model omvat zes centrale eigenschappen van de emotiedynamiek in één keer en kan worden toegepast op relatief korte tijdsreeksen met ontbrekende scores. De gebruikte eigenschappen van emotiedynamiek zijn: de variabiliteit op de lange en korte termijn, de granulariteit, de inertia, de cross-lag regressie en de intensiteit. Het model kan worden toegepast op zowel univariate als multivariate tijdsreeksen, waardoor het de relaties tussen emoties ook kan modelleren. Verder kan het meerdere individuen tegelijk modelleren en indien gewenst externe variabelen meenemen. Het model kan gespecificeerd worden voor niet-normaal verdeelde geobserveerde data en omgaan met ontbrekende scores met behulp van een link functie. Ik laat het nut van het model zien aan de hand van een empirisch voorbeeld met relatief korte tijdsreeksen (47 tot 70 metingen) van drie emoties, met ontbrekende scores in de tijdsreeksen, gemeten voor drie individuen. Ik bespreek hoe het model kan worden uitgebreid en de beperkingen waar men tegenaan kan lopen wanneer het model gebruikt wordt voor de analyse van empirische data.

In **Hoofdstuk 6** pas ik het VAR-BDM toe op bivariate affect-data en vergelijk modellen om het best passende model te vinden. Affectonderzoek richt zich vaak op het bestuderen van verschillende elementaire eigenschappen van de individuele dynamiek van Positief Affect (PA) en Negatief Affect (NA). Deze eigenschappen worden meestal separaat gekwantificeerd, wat het bestuderen van de onderlinge relaties bemoeilijkt. Hier bespreek ik zes elementaire eigenschappen van affect die de dynamiek van PA en NA karakteriseren: de variabiliteit op de lange en korte termijn, de inertia, de cross-lag regressie, de intensiteit en de co-occurrence van affect. Om het bestuderen van deze eigenschappen te faciliteren gebruik ik een vector autoregressief BDM. Dit model bevat parameters die alle zes genoemde eigenschappen van de affect dynamiek kunnen kwantificeren. Het model kan worden toegepast op het soort data dat typisch is voor onderzoek naar affectdynamiek, i.e., bivariate, relatief korte tijd series van verschillende individuen, zo nodig met

ontbrekende scores. Verder kan het model externe variabelen meenemen indien gewenst. Het nut van dit model laat ik zien aan de hand van een empirisch voorbeeld, waarbij ik een dataset gebruik van relatief korte (53 tot 71 metingen), bivariate affectdata van 12 individuen. Om de aanwezigheid van een weekdagefect dan wel een autoregressie in de afwijkingen vast te stellen vergelijk ik drie verschillende modellen. Ik vergelijk de modellen met betrekking tot de ruis, de innovatieruis en een log-likelihood criterium. De modelschattingen geven inzicht in de individuele dynamiek van PA en NA, en de bijbehorende interindividuele verschillen en overeenkomsten.

In dit proefschrift heb ik het effect onderzocht van verschillende schatters en data-eigenschappen op het schatten van de autocorrelatie. Uit mijn onderzoek blijkt dat, van de gebruikte schatters in dit proefschrift, de MLE en de  $B_{sr}$  de beste schatters zijn voor een autoregressief model. Verder blijkt dat het schatten van de autocorrelatie accurater wordt wanneer de tijdreeksen langer zijn, er meer mensen mee doen, de gemiddelde autocorrelatie in een serie groter is en de standaard deviatie van deze autocorrelatie kleiner is.

Daarnaast heb ik gekeken hoe het BDM omgaat met de problemen in empirische data en hoe het psychologische theorieën met statistische modellen kan verbinden. Het BDM kan alle problemen die aanwezig waren in de geanalyseerde datasets aan, d.w.z, missende waarden, de inclusie van externe variabelen en geobserveerde scores met niet-normaal verdeelde residuen. Ook kan het BDM de psychologische onderzoeksvragen beantwoorden die van belang zijn voor de gebruikte datasets, bijvoorbeeld door het vergelijken van modellen om te kijken of een verwacht effect ook werkelijk te vinden is in de data.