
Deze aanvullende informatie is zoals aangeleverd door de auteurs; ze is niet inhoudelijk of taalkundig bewerkt door de redactie van het *Nederlands Tijdschrift Voor Geneeskunde*.

Joinpoint-regressieanalyse

Een joinpoint-regressieanalyse wordt toegepast om breekpunten ('joinpoints') in trends over de tijd te bestuderen. Met deze analyse kunnen tijdpunten worden geïdentificeerd waarop een bepaalde trend significant verandert. Nadat de joinpoints bepaald zijn, kan het gemiddelde percentage verandering tussen twee joinpoints bepaald worden.

Voorspelling van incidentiecijfers

Voor de voorspelling van de incidentiecijfers werden drie Bayesiaanse modellen met elkaar vergeleken, namelijk *Truncated Gaussian Exponential Smoothing models with trend*, *Truncated Gaussian Exponential Smoothing models with dampening and trend*, en *Poisson Exponential Smoothing models with trend*. Op basis van zowel een visuele inspectie alsook op basis van loss functions (absolute mean squared error en root mean squared error) bleek het Poisson model minder goed bij de data te passen dan de Gaussian modellen. Het model met dampening kwam tot vrijwel dezelfde voorspelling als het model zonder dampening, waardoor voor het model met minder vrijheidsgraden (het model zonder dampening) werd gekozen. Dit model heeft een trendcomponent en meet de variantie in die trend om informatie te kunnen geven over de zekerheid waarmee toekomstige datapunten kunnen worden vastgesteld.

Een *Exponential Smoothing model with trend* schat toekomstige datapunten op basis van geobserveerde datapunten en de trend in geobserveerde datapunten, waarbij recente datapunten (en de trend tussen recente datapunten) een sterker gewicht krijgen dan datapunten uit het verleden. Het exacte gewicht dat wordt verleend aan recente datapunten versus datapunten verder uit het verleden wordt door het model geschat. Gewichten worden gebruikt die leiden tot de beste voorspelling van de geobserveerde data; het model bekijkt elk datapunt in de tijdsreeks en probeert die te voorspellen op basis van een weging van data (inclusief de trend in de data) op eerdere tijdspunten; als deze weging voor datapunt t te laag blijkt, zal het model voor het volgende datapunt op $t+1$ proberen een hogere schatting te maken op basis van alle data voorafgaand aan $t+1$, en zo voort. Deze wegingsfactor heet de 'smoothing parameter'. Als het model vaak onderschat of overschat, betekent dit meer variatie in dit schattingspatroon, wat zich vertaalt in meer onzekerheid in de schatting van de smoothing parameter. Dit leidt vervolgens tot een grotere bandbreedte in het voorspellingsinterval voor toekomstige datapunten. Een model dat vaak goed schat heeft weinig onzekerheid en zal dan een smal voorspellingsinterval hebben. Het hele schattingspatroon (de verdeling van de smoothing parameter) wordt namelijk gebruikt om de toekomst te voorspellen.

De figuur met de voorspelling van de incidentiecijfers (figuur 1) toont zowel puntschattingen op basis van de mediaan (50% kwantiel) van de a posteriori verdelingen, alsook die van de 10% en 90% kwantielen (samen het 80% voorspellingsinterval) en van de 2,5% en 97,5% kwantielen (samen het 95% voorspellingsinterval). Voorspellingsintervallen bevatten zowel trendinformatie (puntschattingen) als willekeurige schommelingen (variantie) rondom deze trends. Kansen kunnen direct uit deze a posteriori intervallen afgelezen worden; de kans op toenemende incidentie is bepaald door te berekenen welk deel van de verdeling boven de geobserveerde incidentie in 2022 ligt. Let wel, trends vertonen fluctuatie; zelfs met een stijgende trend in de periode 2023-2035 kunnen door willekeurige observaties in individuele jaren onder de observatie van 2022 terecht komen.