



Delft University of Technology

Verkeersmanagement door simulatie

Beter regelen dankzij nieuwe modelgebaseerde optimaliserende aanpak

Chorus, Caspar; van Cranenburgh, Sander

Publication date

2016

Document Version

Final published version

Published in

NM Magazine

Citation (APA)

Chorus, C., & van Cranenburgh, S. (2016). Verkeersmanagement door simulatie: Beter regelen dankzij nieuwe modelgebaseerde optimaliserende aanpak. *NM Magazine*, 11, 33-38. Article 2.

Important note

To cite this publication, please use the final published version (if applicable).
Please check the document version above.

Copyright

Other than for strictly personal use, it is not permitted to download, forward or 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 such as Creative Commons.

Takedown policy

Please contact us and provide details if you believe this document breaches copyrights.
We will remove access to the work immediately and investigate your claim.

Beter regelen dankzij nieuwe modelgebaseerde optimaliserende aanpak

Verkeersmanagement door simulatie

Om de doorstroming in een netwerk te optimaliseren, moeten we verkeersmanagementmaatregelen in *samenhang* inzetten. Maar hoe bepaal je wat de optimale – meest samenhangende – inzet is? Lange tijd leek het ondoenlijk om zo'n regelprobleem met behulp van (microscopische) modelvoorspellingen op te lossen: het probleem was daarvoor te complex. Een slimme wiskundige techniek die gebruik maakt van verschillende modellen lijkt echter voor een doorbraak te zorgen. Volgens Osorio et al is de nieuwe *modelgebaseerde* optimaliserende aanpak zelfs geschikt voor het doorrekenen van complete netwerken.

Microscopische verkeersmodellen zijn gedetailleerde vraag- en aanbodmodellen die afzonderlijke voertuigen en individuele reizigers simuleren en beschrijven hoe elk van de reizigers beslissingen neemt over bijvoorbeeld de modaliteit, vertrektijd, route en zelfs de rijstrook die ze daarbij gebruiken. Ook details als verkeersregelingen (zoals groentijden) en prioriteiten van het openbaar vervoer worden gemuleerd.

Deze modellen gebruiken we al tientallen jaren om via trial & error verkeerslichten in te regelen, wachtrijen en mogelijke terugslag te bestuderen enzovoorts. We beschikten nog niet over *geautomatiseerde* methoden om regelingen te optimaliseren, maar daar kan snel verandering in komen. In het onderstaande bespreken we kort de kenmerken van het optimalisatieprobleem, we leggen uit waarin de modelaanpak tot nu toe tekortschoot – en laten zien hoe en waarom de nieuwe modelgebaseerde optimaliserende aanpak wél geschikt is voor het (geautomatiseerd) optimaliseren van netwerken.

Het optimalisatieprobleem

We gaan er in het navolgende vanuit dat we de beschikking hebben over een gekalibreerd microsimulatiemodel waarmee we het functioneren van een reeks verkeerslichten kunnen beoordelen. Het is een *stochastisch model*, wat betekent dat de uitkomst van een run elke keer verschilt en de facto een trekking is uit een stochastische verdeling.

We gebruiken de notatie $F = F(x, y; p)$ om dit uit te drukken. Hier staat de beslissingsvector x voor de variabelen van de verkeersregeling, zoals de groentijden. De functie F beschrijft een stochastische waarde van de te optimaliseren prestatie maat, zoals totale verliestijd, totale reistijd of totale emissie. Deze waarde hangt natuurlijk af van

de verkeersregeling x , maar ook van andere endogene variabelen van het simulatiemodel y . Denk dan aan de capaciteiten van de links, de routekeuzekansen enzovoort. Ook (vaste) simulatieparameters p spelen een rol: de herkomst-bestemmingsmatrix, netwerktopologie, het openbaar-vervoernetwerk etc.

Stel dat we op zoek zijn naar de regeling x^* die de gemiddelde prestatie van het netwerk optimaliseert. We kunnen het optimalisatieprobleem dan beschrijven als:

$$x^* = \arg \min f(x)$$

waarin $f(x) = E(F(x, y; p))$ de verwachte waarde is die we krijgen als we oneindig veel simulaties zouden uitvoeren. Hierbij moeten we natuurlijk rekening houden met het feit dat x^* netjes aan alle randvoorwaarden moet voldoen, met andere woorden: x^* moet realiseerbaar zijn.

De grootste uitdaging bij het aanpakken van dit soort problemen is dat we $f(x)$ niet zomaar kunnen uitschrijven in een paar wiskundige formules: we kunnen de te optimaliseren functie $f(x)$ alleen maar schatten met behulp van een stochastische simulatie. Om dat goed te doen moeten we voldoende simulaties uitvoeren, totdat de juiste verkeersregeling is gevonden. We noemen deze aanpak *Simulation-based Optimisation (SO)*.

Netwerkniveau?

Voor simpele problemen (een kruispunt) werkt deze methode uitstekend: dankzij SO-algoritmes kunnen we inderdaad de optimale re-

gelaanpak vinden. Onderzoekers gingen daarom al snel op zoek naar meer: zouden we de SO-aanpak kunnen gebruiken om te bepalen hoe we *meerdere* verkeersmanagementmaatregelen in *samenhang* kunnen inzetten?

Het antwoord was nee. Het probleem is namelijk dat er met de gewone SO-aanpak niet gericht wordt gesimuleerd. Simpel gezegd: het model beschikt niet over kennis van het achterliggende probleem, maar ontdekt ‘simulerenderwijs’ wat de beste oplossing is. Daarbij wordt bijvoorbeeld gebruik gemaakt van principes uit de biologie, zoals evolutie in een genetisch algoritme. Dat is nog te doen als het om een enkele verkeersregeling gaat, maar het op deze wijze doorrekenen van een wat groter netwerk met meerdere maatregelen vereist zoveel simulaties, dat de benodigde rekentijd te lang is. Het toegepaste onderzoek verlegde de aandacht daarom naar alternatieve aanpakken, zoals HERO, de aanpak Gecoördineerd Netwerkbreed Verkeersmanagement (GNV, zoals ontwikkeld binnen de Praktijkproef Amsterdam) en de decentrale Backpressure-methode.

Nieuwe SO-aanpak

Maar zoals gezegd: er gloort hoop. In 2013 ontwikkelden Osorio en Bierlaire *et al* een nieuw, efficiënter algoritme dat ervoor zorgt dat we veel gericht simuleren.^{*} Het betreft in feite een SO-metamodel dat de output van de simulator slim combineert met de informatie van een simpel macroscopisch analytisch en differentieerbaar verkeersmodel als MARPLE, STAQ of nog iets veel eenvoudigers. In principe kunnen we gebruik maken van elk model, zolang we maar de afgeleide $\nabla m(x)$ van de beslisvector x naar de modeluitkomsten $m(x)$ kunnen uitrekenen en we het model kunnen ‘fitten’ op de uitkomsten van het simulatiemodel.

In deze bijdrage gaan we uit van een eenvoudig analytisch wachtrijmodel, waarmee we op rudimentaire wijze de terugslag van wachtrijen beschrijven. Dit model maakt het mogelijk om de doelfunctie analytisch te benaderen.

We veronderstellen de volgende vorm:

$$m(x, y; \alpha, \beta, q) = \alpha \cdot f_A(x, y; q) + \phi(x; \beta)$$

Hierin is $f_A(x, y; q)$ de benadering van de prestatie van het netwerk, gegeven de beslisvector x en de endogene variabelen z , waaronder de verdeling van de lengte van de wachtrijen die we kunnen afleiden uit het toepassen van het simulatiemodel. De parameters α en β (schaalparameters) en het functionele deel van het metamodel $\phi(x; \beta)$ worden gebruikt om het model te ‘fitten’ op de uitkomsten van het simulatiemodel.

In Osorio *et al* (2015) wordt het volgende metamodel afgeleid:

$$f_A = \sum_i \rho_i \left(\frac{1}{1 - \rho_i} - (l_i + 1) \frac{\rho_i^{l_i}}{1 - \rho_i^{l_i+1}} \right)$$

Hierin stellen i alle relevante wachtrijen voor en l_i de maximale lengte van deze wachtrijen (voordat ze terugslaan); ρ_i is de verhouding tussen de aankomstintensiteit en de *service rate* voor de wachtrij i .^{**}

^{*} C. Osorio, M. Bierlaire *et al*, A simulation-based optimization framework for urban transportation problems, *Operations Research* 61 (6) (2013) 1333–1345.

^{**} Zie voor meer details: Osorio *et al*, Reducing gridlock probabilities via simulation-based signal control, *Transportation Research Procedia* 6 (2015) 101 – 110.

Hierbij gaan we ervan uit dat we de totale reistijd in het netwerk proberen te minimaliseren.

We zullen nu de iteratieve methode toelichten aan de hand van figuur 1. In een gegeven iteratie k doorloopt het algoritme de volgende stappen:

- 1) Fit het metamodel m_k , uitgaande van de simulatieresultaten tot nu toe. Anders gezegd: bepaal α , β en z .
- 2) Gebruik m_k om een optimalisatie uit te voeren en leid een zogenaamd *trial point* x_k af.
- 3) Evalueer de prestaties op dit *trial point* met behulp van de simulator. Dit leidt tot nieuwe simulatieresultaten.

Elk nieuw simulatieresultaat verbetert de nauwkeurigheid van het metamodel. Dit leidt vervolgens tot een beter *trial point* met verbeterde prestaties. Deze stappen kunnen net zo lang worden herhaald totdat de rekencapaciteit (rekentijd) ‘op’ is.

De crux van deze metamodel-benadering is dus dat we de (inefficiënte) stochastische respons van de simulatie vervangen door een deterministische metamodel-responsfunctie m , en wel op zo’n manier dat we (efficiënte) deterministische optimalisatietechnieken kunnen gebruiken.

De casestudie

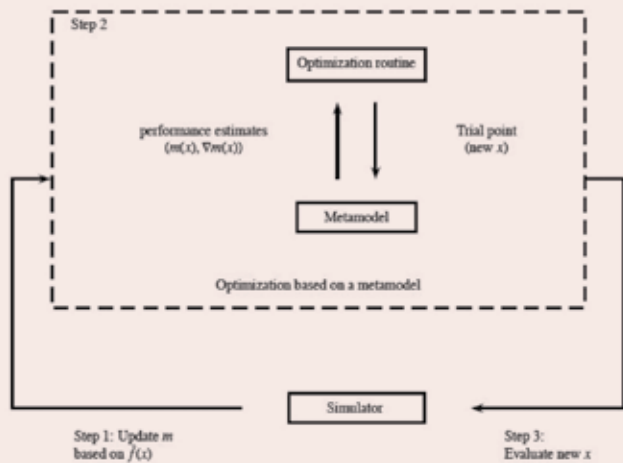
Om te illustreren dat de aanpak met een SO-metamodel inderdaad goed werkt, gaan we tot slot kort in op een interessante casestudie met betrekking tot Manhattan, New York. Voor deze studie hebben we een microscopisch verkeerssimulatiemodel van de New York City Department of Transportation (NYCDOT) gebruikt, gebruikmakend van Aimsun-software. Het model is gekalibreerd voor de doorweekse ochtendspits. Het beschouwde netwerk betreft oostelijk Manhattan – zie figuur 2.

We vergelijken de prestaties van de regelingen die het SO-algoritme van het metamodel voorstelt (aangeduid met m), met de regelingen die NYCDOT momenteel in dat gebied gebruikt. Het SO-algoritme wordt ingezet met een limiet (budget) van 150 simulaties. Dat wil zeggen: zodra er 150 simulatieruns zijn uitgevoerd, stoppen we het algoritme en wordt uit die set het beste regelplan voor *upper east* Manhattan gekozen.


Met behulp van een simulator evalueren we beide regelplannen – de bestaande en het plan dat met de SO-methode is ontwikkeld. We schatten daarbij de volgende prestaties: (a) de verwachte totale wachtrijlengte in het netwerk; (b) de verwachte reistijd (minuten); (c) de verwachte dichtheid gemeten over het gehele netwerk (voertuigen per km); (d) de totale kans op terugslag, oftewel de som van alle terugslagkansen van alle wachtrijen; en (e) de verwachte netwerkcapaciteit (voertuigen per uur).

Om deze prestatie-indicatoren goed te kunnen schatten voeren we per regelplan 50 simulaties uit. Vervolgens plotten we de empirische cumulatieve verdelingsfunctie (*cumulative distribution function*, CDF) van elke prestatie-indicator. Elke CDF-curve bestaat dus uit 50 simulatieschattingen van de betreffende indicator. De ‘plots’ in figuur 3 betreffen steeds één indicator van twee regelplannen, waarbij de doorlopende lijn staat voor het bestaande regelplan en de stippellijn voor de SO-variant.

Uit figuur 3-a blijkt dat het voorgestelde SO-plan tot een aanzienlijke vermindering van de totale wachtrijlengte leidt: de gemiddelde vermindering ligt rond 26%. De maximale wachtrijlengte blijft bij een



Figuur 1: SO-methode die gebruik maakt van een metamodel.



Figuur 2: Het in Aimsun gesimuleerde netwerk in de casestudie: upper east Manhattan..

op SO gebaseerd plan beperkt tot 400 voertuigen, wat lager is dan de kleinste waarde van het bestaande plan.

Figuur 3-b laat zien dat met het SO-plan de verwachte reistijd afneemt met gemiddeld 10%. Ook de verwachte dichtheid neemt af (3-c), terwijl de netwerkcapaciteit (3-e) juist toeneemt.

Interessant is ook figuur 3-d, die laat zien dat de kans op terugslag significant afneemt. Gemiddeld gaat het om een 25% kleinere kans. Dit toont aan dat het met het gebruikte algoritme goed mogelijk is om het terugslaan van wachtrijen *netwerkbreed* terug te dringen – en daarmee de kans op (extra) congestie te verminderen. Ook is de spreiding van de kans veel kleiner, wat duidt op extra stabiliteit.

Conclusies

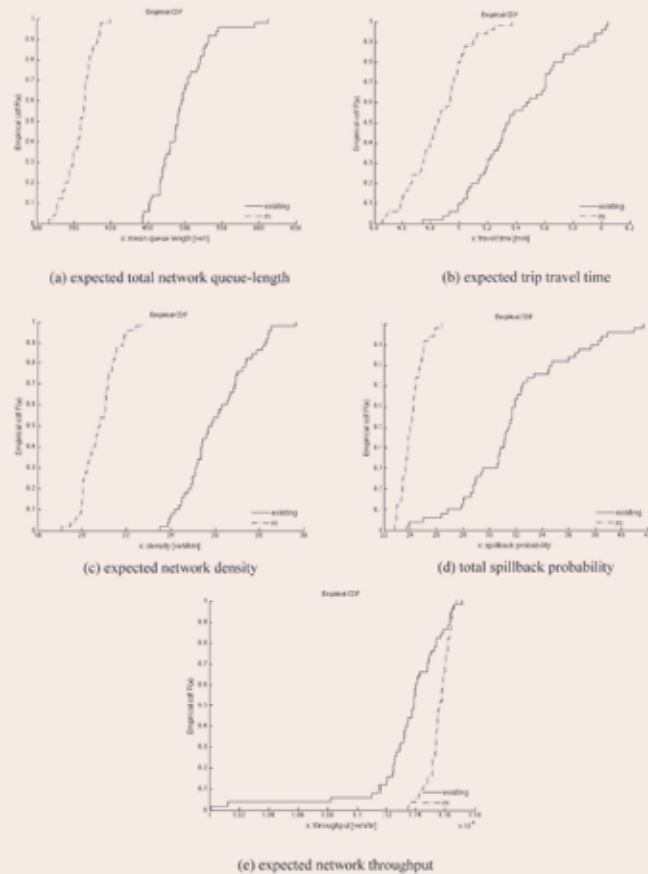
Al met al is het SO-metamodel een zeer veelbelovende methode om verkeersregelingen in een netwerk te optimaliseren. Zoals de Manhattan-case van hiervoor laat zien, zijn er ronduit spectaculaire verbeterlagen mogelijk in de afhandeling van het verkeer.

Voor de komende tijd is het zaak om de theorie en de kennis opgedaan in de cases verder te beproeven en te vertalen naar geautomatiseerde toepassingen. Als dat lukt dan kunnen we met recht spreken van een regelrechte doorbraak in netwerkmanagement ●

De auteurs

Dr. Carolina Osorio is *assistant professor* aan de *Massachusetts Institute of Technology*.

Prof. dr. ir. Serge Hoogendoorn is *hoogleraar Verkeersstromen* aan de *Technische Universiteit Delft*.



Figuur 3a: Totale wachtrijlengte, b) Reistijd, c) Dichtheid, d) Kans op terugslag en e) Netwerkcapaciteit.

Innovaties in keuzemodellen

Keuzemodellen modelleren het keuzegedrag van mensen op een wiskundige manier. Ze worden over de hele wereld gebruikt om keuzegedrag kwantitatief te analyseren en te voorspellen. Toepassingen variëren van stemgedrag van kiezers tot consumentenvoorkeuren voor de nieuwste smartphone. Maar ook onze *mobilitateitskeuzes* laten zich prima modelleren. Hoe dat werkt en hoe een en ander zich in de afgelopen decennia ontwikkeld heeft, bespreken we in deze tutorial Keuzemodellen.



In het transportdomein spelen keuzemodellen een cruciale rol. Om maar een paar toepassingen te noemen: we gebruiken ze voor de analyse en optimalisatie van verkeersstromen, we voorspellen er de effecten van nieuwe transporttechnologieën mee en keuzemodellen vormen de basis van maatschappelijke kosten-batenanalyses.

Gegeven het belang van deze modellen voor ons vakgebied, is het niet verbazingwekkend dat veel van de belangrijkste innovaties in keuzemodellen hun oorsprong vinden in ons transportdomein. Reden om in deze tutorial de belangrijkste ontwikkelingen van de laatste decennia op een rij te zetten.

De basis: het Logit-model

Begin jaren 1970 introduceerde Daniel McFadden het zogeheten *Logit*-model. Centraal in dit model staat de logit-keuzekansformule. Deze formule bestond al langer, maar het was McFadden die er een econometrische conceptualisatie aan verbond die in één klap een fundamenteel bood voor de analyse van keuzegedrag. Het door McFadden ontwikkelde *Random Utility Maximization (RUM) Logit*-model is gebaseerd op de veronderstelling dat mensen het alternatief (bijvoorbeeld: de vervoerswijze) kiezen met het hoogste nut (U), en dat we een deel (V) van dit nut kunnen verklaren door de kenmerken van het bewuste alternatief. Dit zogenaamde systematische nut V is een functie van relevante factoren en hun gewicht: bijvoorbeeld de reistijd en rijstijdbetrouwbaarheid van een vervoerswijze, en het

belang van beide factoren voor de reiziger. Een ander deel van het nut wordt niet bekend verondersteld ('niet geobserveerd'). Wanneer we aannemen dat dit deel van het nut zijn eigen statistische verdeling heeft – we modelleren het niet-geobserveerde nut met een storingsterm ϵ – dan komen we voor de keuzekans P op de volgende eenvoudige formule:

$$P_i = \frac{\exp(V_i)}{\sum_j \exp(V_j)}$$

Omdat deze formule een gesloten vorm heeft, kunnen we heel gemakkelijk de kans P berekenen dat alternatief i gekozen wordt uit een keuzeset met J alternatieven.

In de jaren zeventig van de vorige eeuw opende dit de deur om op een nieuwe gedesaggreerde manier reizigersgedrag te voorspellen. Nadat een keuzemodel is geschat op basis van geobserveerde keuzes (van bijvoorbeeld vervoerswijze), kan de onderzoeker het belang van de verschillende factoren statistisch bepalen. Bijvoorbeeld: hoeveel belangrijker is reistijdwinst dan een verhoging van de reistijdbetrouwbaarheid? Ook kunnen we het keuzemodel gebruiken om het marktaandeel van een nieuw stuk snelweg of een nieuwe OV-verbinding te voorspellen.

Innovaties in de 20e eeuw

In de eerste twee decennia sinds de introductie van het Logit-model waren de meeste innovaties in keuzemodellen gericht op de storingsterm ϵ . Het bleek namelijk dat de meest praktische specificatie van deze term in veel gevallen onrealistische voorspellingen opleverde. Dit was met name het geval wanneer er sprake was van een keuzeset waarin sommige alternatieven veel op elkaar leken, en dus kenmerken deelden. Denk bijvoorbeeld aan een keuze tussen de auto, tram en bus: de laatste twee opties zijn beiden OV en delen dus een aantal kenmerken. In zo'n geval geeft de storingsterm van het Logit-model geen goede weergave van wat het probeert te modelleren (het niet-geobserveerde nut), en dit leidt tot verkeerde voorspellingen.

Onderzoekers kwamen al snel met alternatieve specificaties, die meer realistisch keuzegedrag voorspelden. Sommige van deze modellen hebben inmiddels ook ruimschoots hun weg gevonden naar de beroepspraktijk. Denk aan het *Nested Logit*-model, het *Cross-Nested Logit*-model, en het *Path-Size Logit*-model.

Sinds de eeuwwisseling is de aandacht voor de storingsterm afgenomen, deels omdat de belangrijkste verbeteringen al zijn bedacht. In het vervolg van deze richtingen we ons daarom op enkele andere innovaties van recentere datum.

De wiskunde van gedrag

Traditioneel gezien hechten de ontwerpers van keuzemodellen zeer aan verankering in klassieke economische axioma's van rationeel keuzegedrag, en aan gebruiksvriendelijkheid van het model. Neem bijvoorbeeld de specificatie van het systematisch nut V in de context van een afweging tussen reistijd T en reistijdbetrouwbaarheid B . De meest praktische en rationele specificatie van V is lineair-additief:

$$V = \gamma \cdot T + \theta \cdot B$$

In woorden: de reiziger beoordeelt de vervoerswijze op beide factoren, en vermenigvuldigt elke score met het bijbehorende gewicht. De som van deze deelnutten geeft de eindscore, ofwel het totale systematisch nut van de vervoerswijze. Deze specificatie van V klinkt heel intuïtief, maar decennia van gedragsonderzoek heeft aangetoond dat werkelijk keuzegedrag vaak lang niet zo rationeel tot stand komt als door dit model verondersteld wordt.

Zo toonden Daniel Kahneman en Amos Tversky in hun Nobelprijswinnende *Prospect Theory* aan, dat het niet zozeer de absolute waarden van bijvoorbeeld reistijd en betrouwbaarheid zijn die ertoe doen, maar hoe deze waarden zich verhouden tot het referentiepunt van de reiziger. Een negatieve afwijking ten opzichte van het referentiepunt – bijvoorbeeld een reistijd die langer is dan die van de gebruikelijke route – telt bovendien aanmerkelijk zwaarder dan een positieve afwijking. Deze 'verliesaversie' is inmiddels ook breed geaccepteerd in de economische wetenschap, en er zijn verschillende keuzemodellen die er rekening mee houden.

Het grootste probleem van deze op verliesaversie gebaseerde keuzemodellen, is dat het niet evident is wat het referentiepunt is van de reiziger, en dus welk referentiepunt de onderzoeker moet gebruiken in zijn keuzemodel. Neem het voorbeeld van routekeuze en reistijd. Is de reistijd op een gemiddelde dag het referentiepunt, of de 'free flow' reistijd zonder vertraging, of de door de reiziger verwachte reistijd? Recent onderzoek laat zien dat afhankelijk van het door de onderzoeker gekozen referentiepunt, de modeluitkomsten flink uiteen kunnen lopen. Dit is een interessant maar ook zorgwekkend inzicht: er is nog heel wat vervolgonderzoek nodig over de rol van referentiepunten in keuzegedrag!

Ook aan de TU Delft worden keuzemodellen ontwikkeld die uitgaan van beperkte rationaliteit. De door ons ontwikkelde aanpak is gebaseerd op het in de gedragswetenschappen zeer gangbare idee dat mensen bij het maken van keuzes spijt achteraf willen vermijden (in tegenstelling tot de veronderstelling dat mensen nut maximaliseren). Dit zogenaamde spijtmodel is verwant aan de hierboven genoemde notie van verliesaversie, met als belangrijkste verschil de specificatie van het referentiepunt: het spijtmodel gaat ervan uit dat mensen de verschillende keuzealternatieven vergelijken op *elke afzonderlijke factor*. De prestaties van de concurrerende alternatieven vormen het referentiepunt. Bijvoorbeeld: de reistijd van een route wordt vergeleken met de reistijd van elke andere route en hetzelfde gebeurt voor reistijdbetrouwbaarheid. Is jouw route langzamer dan een concurrent, dan levert dat spijt op. Hoe groter het verschil, en hoe groter het gewicht dat je hecht aan reistijd, hoe groter de spijt. Net als in *Prospect Theory*, krijgt spijt een zwaarder gewicht dan zijn positieve tegenhanger, door economen 'rejoice' genoemd.

In formulevorm ziet de spijt die een reiziger anticipeert bij het vergelijken van de reistijd van twee mogelijke vervoerswijzen er als volgt uit:

$$r = \mu \cdot \ln\left(1 + \exp\left(\frac{\gamma}{\mu} \cdot \Delta T\right)\right)$$

Hier staat ΔT voor het verschil in reistijd tussen de twee alternatieven. Spijtaversieparameter μ wordt geschat, en geeft aan hoeveel meer gewicht mensen in een bepaalde keuzesituatie hechten aan spijt dan aan 'rejoice'. Als beide aspecten even belangrijk blijken te zijn, is het spijtmodel equivalent aan het klassieke, lineair-additieve nutsmodel. De elegantie van dit zogenaamde μ RRM-model zit hem dus in het feit dat de onderzoeker niet a priori hoeft te kiezen voor een bepaalde beslisregel – spijt of nut.

Dit model is inmiddels opgenomen in de meest gebruikte economische softwarepakketten.

Het modelleren van heterogeniteit

Geen mens maakt keuzes op exact dezelfde manier en ook is geen keuzesituatie gelijk. Er is om die reden veel onderzoek verricht naar het modelleren van *heterogeniteit* in keuzegedrag. In eerste instantie probeerden onderzoekers heterogeniteit te vangen door segmentatie op basis van bijvoorbeeld geslacht, opleidingsniveau of inkomen. Zo kon men bijvoorbeeld achterhalen of hoger opgeleiden een ander gewicht toekenden aan reistijdonbetrouwbaarheid dan lager opgeleiden. Hoewel dit type heterogeniteit belangrijk is en deze segmentatiemodellen nog steeds veel gebruikt worden, zijn ze onvolledig: ze missen de aanzienlijke heterogeniteit *binnen* segmenten. Met andere woorden, ook twee personen met dezelfde sociodemografische achtergrond kunnen zeer van elkaar verschillen in keuzegedrag. Econometristen noemen dit ongeobserveerde heterogeniteit.

Sinds de ontdekking van het Logit-model wisten onderzoekers al hoe ze ongeobserveerde heterogeniteit moesten modelleren: door parameters (de gewichten) volgens een statistische verdeling te laten variëren tussen mensen. Zo kan het gewicht van de factor 'reistijd' een verdeling in de populatie volgen. Hoewel iedereen lagere reistijden zal prefereren, varieert de mate waarin men gevoelig is voor reistijd aanzienlijk in de populatie. Het *Mixed Logit*-model, dat dit type ongeobserveerde heterogeniteit kan modelleren, produceert aanzienlijk betere voorspellingen dan (al dan niet gesegmenteerde) conventionele Logit-modellen.

Toch duurde het ruim 25 jaar voordat het Mixed Logit-model populair werd. De reden is simpel: tot de eeuwwisseling was de reken capaciteit van computers niet toereikend om de integralen van het Mixed Logit-model uit te rekenen. Nog steeds kan het dagen duren voordat een Mixed Logit-model geschat is, zeker als het aantal integralen oploopt, wat het geval is als de onderzoeker vermoedt dat meerdere gewichten variëren in de populatie.

De afgelopen paar jaar is het Mixed Logit-model op zijn beurt onderwerp van kritiek geworden. De reden? Het is niet flexibel genoeg, omdat het vereist dat de onderzoeker a priori de statistische verdeling van de gewichten bepaalt. Deze verdeling (bijvoorbeeld de Normaalverdeling of de Lognormaalverdeling) hoeft niet overeen te komen met hoe de gewichten werkelijk variëren binnen de populatie. Bovendien blijkt dat de modeluitkomsten sterk beïnvloed worden door de gekozen verdeling. De oplossing voor deze uitdaging is onlangs gevonden in zogenaamde *Latente Klasse*-modellen. Deze veronderstellen dat er verschillende klassen van individuen zijn, en dat elke klasse verschilt in termen van gewichten en beslisregels. In plaats van dat de onderzoeker van tevoren specificiert hoeveel klassen er zijn, wie in welke klasse zit, en hoe de klassen van elkaar verschillen in gewichten en beslisregels, wordt dit overgelaten aan het proces van modelschatting. Met andere woorden, de data spreken voor zich. Recent onderzoek laat zien, dat deze Latente Klasse-modellen het niveau van modelleren weer een trede hoger hebben getild, omdat ze flexibeler zijn dan Mixed Logit-modellen en minder afhankelijk zijn van inschattingen van de onderzoeker. Ze leveren ook waardevolle informatie op over de verdeling van gewichten en beslisregels over de populatie. Ze staan toe om te testen wat er nu precies voor zorgt dat bepaalde individuen (met bepaalde persoons- en situatietekenen) behoren tot een bepaalde klasse. Welke kenmerken bepalen of iemand bijzonder spijtavers is, of bovengemiddeld waarde hecht aan betrouwbare reistijden? Tot slot: we kunnen zonder veel problemen elementen van segmentatie- en Mixed Logit-modellen integreren in Latente Klasse-modellen, wat hun aantrekkingskracht verder vergroot.

Innovaties in dataverzameling: keuze-experimenten


Een keuzemodel is zo betrouwbaar als de data waarmee het geschat is. Veel van het onderzoek in ons vakgebied gaat dan ook over dataverzameling: hoe observeer je keuzes die een betrouwbare basis vormen voor modelschatting en -toepassing? Traditioneel zijn zogenaamde *Stated Preference* (SP)-data populair in mobiliteitsonderzoek. Deze data verzamelen we met behulp van zogenaamde keuze-experimenten, waarin deelnemers wordt gevraagd om te kiezen uit een set van hypothetische alternatieven. De voordelen van deze manier van dataverzameling zijn evident: de experimentele opzet zorgt voor systematiek en controle. Ook is het mogelijk om met de SP-methode keuzes voor nog niet bestaande alternatieven, zoals een nieuwe OV-dienst, te onderzoeken.

Inmiddels zijn onderzoekers erin geslaagd om *optimale SP-experimenten* te ontwerpen, die efficiënt zijn in de zin dat ze met een minimaal aantal respondenten betrouwbare modelschattingen garanderen. Innovaties op dit gebied zitten met name in het optimaliseren van experimenten voor de steeds betere modellen die beschikbaar komen. Zo toont onderzoek van de TU Delft in samenwerking met de Universiteit van Sydney aan, dat een experiment dat optimaal is voor nutsmaximaliserend keuzegedrag, bijzonder inefficiënt kan zijn voor de analyse van spijtgebaseerd keuzegedrag. Hetzelfde geldt voor experimenten die voor Mixed Logit versus standaard Logit geoptimaliseerd zijn. Hiervoor is inmiddels gebruiksvriendelijke software ontwikkeld, zodat ook buiten de we-

tenschap het gebruik van efficiënte keuze-experimenten gemeengoed aan het worden is.

Conclusie

Keuzemodellen spelen al ruim veertig jaar een cruciale rol in het transportdomein. Er is in die tijd grote vooruitgang geboekt, bijvoorbeeld in het modelleren van beperkt rationeel gedrag en heterogeniteit, en in het efficiënt verzamelen van betrouwbare data. Veel van deze ontwikkelingen hebben inmiddels hun weg gevonden naar de beroepspraktijk, waar ze leiden tot betere voorspellingen van verkeer en mobiliteit. De relevantie van deze ontwikkelingen voor de beleidspraktijk is moeilijk te overschatten ●



De auteurs

Prof. dr. ir. Caspar Chorus is hoogleraar *Choice behavior modeling* aan de TU Delft en hoofd van de sectie Transport en Logistiek.

Dr. ir. Sander van Cranenburgh is universitair docent aan de TU Delft