

# **Real-time reistijdvoorspellingen voor routekeuze- en vertrektijdstipadvies - een toepassing in de Praktijkproef Amsterdam**

Maaike Snelder – TNO – maaike.snelder@tno.nl

Simeon Calvert – TNO – simeon.calvert@tno.nl

## **Bijdrage aan het Colloquium Vervoersplanologisch Speurwerk 19 en 20 november 2015, Antwerpen**

### **Samenvatting**

Op wegen in en tussen stedelijke gebieden wordt vaak veel verkeer afgewikkeld. De keerzijde hiervan is dat er verwacht en onverwacht reistijdverlies ontstaat als de vraag de capaciteit overschrijdt. Diverse maatregelen kunnen worden ingezet om reistijden te verkorten en reistijdverlies tegen te gaan. Dit artikel richt zich op vertrektijdstip- en routekeuze-advies waarbij de nadruk ligt op de reistijdvoorspellingen die nodig zijn om een hoogwaardig advies te kunnen geven. Vervoerwijze-, routekeuze- en vertrektijdstipadvies vindt nog veelal plaats op basis van historische en instantane reistijden, terwijl betere adviezen kunnen worden gegeven als rekening wordt gehouden met reistijdvoorspellingen.

Dit artikel presenteert een raamwerk waarin zes verschillende op model en op data gebaseerde reistijdvoorspelmethodes real time parallel draaien. Afhankelijk van de situatie (voorspelhorizon, dag van de week, tijdstip, wegtype, regulier/incident) wordt de naar verwachting meest accurate methode gekozen. De gekozen voorspelmethodes zijn voornamelijk datagedreven methodes. Deze keuze is gemaakt om kalibratieproblemen te beperken en omdat deze methodes over het algemeen een kortere rekentijd hebben dan simulatiemethodes. Voor incidentsituaties op het hoofdwegennetwerk bestond nog geen goede reistijdvoorspelmethode. In dit artikel wordt daarom een nieuw hybride (data en simulatie) real-time marginaal incidentmodel geïntroduceerd waarmee realtime de verwachte extra reistijd kan worden berekend bij incidenten op het hoofdwegennetwerk.

Het raamwerk is ingezet in de Praktijkproef Amsterdam met als doel om via gepersonaliseerde in-car informatie in Amsterdam en omgeving de voertuigverliesuren te beperken, de reistijdbetrouwbaarheid te vergroten en de bereikbaarheid te verbeteren. Dit artikel beschrijft de kwaliteit van de reistijdvoorspellingen en het gebruik van de voorspellingen voor routekeuze- en vertrektijdstipadvies. De Praktijkproef Amsterdam heeft aangetoond dat het geïntroduceerde raamwerk het mogelijk maakt om binnen 1 minuut voorspellingen voor het hele Nederlandse hoofdwegennetwerk en een groot deel van het onderliggende wegennetwerk rondom Amsterdam te maken op basis van grote hoeveelheden data.

## **1. Inleiding**

Op wegen in en tussen stedelijke gebieden wordt vaak veel verkeer afgewikkeld. De keerzijde hiervan is dat er verwacht en onverwacht reistijdverlies ontstaat als de vraag de capaciteit overschrijdt. Diverse maatregelen kunnen worden ingezet om reistijden te verkorten en reistijdverlies tegen te gaan. Dit artikel richt zich op vertrektijdstip- en routekeuze-advies waarbij de nadruk ligt op de reistijdvoorspellingen die nodig zijn om een hoogwaardig advies te kunnen geven. Vervoerwijze-, routekeuze- en vertrektijdstipadvies vindt nog veelal plaats op basis van historische en instantane reistijden, terwijl betere adviezen kunnen worden gegeven als rekening wordt gehouden met verwachte reistijden (Bellemans et al., 2002; Hegyi, 2004).

Reistijdvoorspellingen kunnen met behulp van verschillende methodes worden gegenereerd. Hierbij kan onderscheid worden gemaakt naar statische en dynamische methodes, microscopische, mesoscopische en macroscopische modellen, offline en online modellen, datagedreven en modelgedreven methodes en deterministische en stochastische methodes. Binnen deze klassen kan nog nader onderscheid worden gemaakt naar verschillende methodes. Aangezien alle methodes hun sterke en zwakke punten kennen, bestaat er geen enkele methode die in alle situaties beter is dan een andere methode. Verschillende voorspelhorizonten, locaties, wegtypes, tijdstippen, dagen van de week en situationele variabelen zoals weersomstandigheden, incidenten etc. vragen om verschillende benaderingen. In dit artikel introduceren we daarom een raamwerk waarin een combinatie van verschillende op model en op data gebaseerde methodes parallel draaien. Afhankelijk van de situatie die zich voordoet, wordt de naar verwachting meest accurate methode gekozen. Bovendien introduceren we in dit artikel een nieuw reistijdvoorspeller die bij incidenten op het hoofdwegenetwerk realtime kan worden ingezet<sup>1</sup>.

Het raamwerk is ingezet in de Praktijkproef Amsterdam met als doel om via gepersonaliseerde in-car informatie in Amsterdam en omgeving de voertuigverliesuren te beperken, de reistijdbetrouwbaarheid te vergroten en de bereikbaarheid te verbeteren.

Paragraaf 2 van dit artikel gaat nader in op bestaande methodes voor reistijdvoorspellingen. In paragraaf 3 wordt het raamwerk gepresenteerd. Paragraaf 4 gaat in op de verschillende reistijdvoorspellers die worden ingezet in de Praktijkproef Amsterdam. Paragraaf 5 gaat vervolgens nader in op de Praktijkproef Amsterdam, de kwaliteit van de reistijdvoorspellingen en het gebruik van de voorspellingen voor routekeuze- en vertrektijdstipadvies. De laatste paragraaf gaat in op de conclusies en vervolgstappen.

## **2. Bestaande methodes**

Zoals in de inleiding aangegeven bestaan er veel verschillende methodes om reistijdvoorspellingen mee te maken. Deze paragraaf richt zich op simulatiemethodes en op data-gebaseerde methodes.

---

<sup>1</sup> Dit artikel is gebaseerd op (Calvert et al., 2015)

## 2.1 Simulatiemethodes

Deze paragraaf gaat kort in op micro- en macroscopische simulatiemodellen. Mesoscopische modellen zijn hier een tussenweg in. Microsimulatiemodellen beschrijven individuele voertuigen en het rijgedrag van bestuurders. Bij rijgedrag wordt onderscheid gemaakt naar longitudinaal rijgedrag (voertuigvolgedrag en vrije snelheidskeuze) en lateraal rijgedrag (rijstrookkeuze bij inhalen, 'ritsen', invoegen, voorsorteren etc.). Deze modellen kunnen worden ingezet op snelwegen en andere wegen. De uitkomsten van de microsimulatiemodellen kunnen zeer veel detail bevatten tot aan de positie van de voertuigen op de weg op ieder tijdstip, maar deze methode kan ook gebruikt worden voor reistijdvoorspelling. Voordelen van deze methode zijn de visualisatiemogelijkheden van de resultaten en de mogelijkheden om maatregelen die het rijgedrag beïnvloeden te modelleren. Het is echter lastig om microsimulatiemodellen te kalibreren. Daarnaast is niet gegarandeerd dat het optellen van individuele voertuigen een stabiel geaggregeerd resultaat geeft voor het collectief. Bovendien kan de rekentijd snel oplopen. Voor grote netwerken is het vaak vereist om een langere voorspelhorizon te hanteren (Knoop et al., 2013). Een groter netwerk betekent meer voertuigen en dus langere rekestijden. De rekentijd kan groter worden dan realtime, waarmee het onmogelijk wordt om dergelijke modellen voor realtime reestijdvoorspelling te gebruiken.

Reestijdvoorspellingen kunnen ook met macroscopische modellen worden gemaakt. Hierbij worden stromen van voertuigen gemodelleerd op basis van een fundamenteel diagram die de relatie weergeeft tussen de dichtheid van de voertuigen, de intensiteit en de snelheid. Een bekend voorbeeld van een macroscopisch verkeersafwikkelingsmodel is het celtransmissiemodel (Daganzo, 1994; Daganzo, 1995). Een dergelijk model beschrijft het verkeer door wegen op te splitsen in cellen en bepaalt hoe het verkeer van cel naar cel stroomt. Linktransmissiemodellen (Yperman, 2007) vereisen geen splitsing in cellen waardoor ze een kortere rekentijd kennen. Het voordeel van macroscopische modellen is dat op geaggregeerd niveau naar het functioneren van het netwerk wordt gekeken. Dat maakt het mogelijk om ook op geaggregeerd niveau te kalibreren bijvoorbeeld op basis van intensiteiten. Een nadeel van macroscopische modellen is dat het lastiger is om bij irreguliere situaties te bepalen hoe die het collectieve gedrag beïnvloeden. Macroscopische modellen werken goed op snelwegen. In stedelijk gebied werken ze minder goed en is het vereist dat het model een goed knooppuntmodel heeft (Tampère et al., 2011). De afgelopen jaren zijn marginale modellen een veelbelovende toevoeging gebleken aan macroscopische modellen. Dergelijke modellen berekenen op basis van een basisrun met een macroscopisch model alleen wat het marginale effect is van bijvoorbeeld een verstoring of een maatregel met een veel kortere rekentijd als gevolg. Deze modellen zijn met name effectief gebleken als kleine veranderingen in de capaciteit of de vraag vaak moeten worden doorgerekend (Corthout et al., 2014; Corthout et al., 2011; Himpe and Tampère, 2013). Voor realtime reestijdvoorspelling zijn dergelijke modellen bruikbaar vanwege de korte rekentijd.

## 2.2 *Datagedreven methodes voor reistijdvoorspellingen*

Datagedreven methodes, zoals statistiek en 'machine learning' of 'artificial intelligence' kunnen ook worden gebruikt voor reistijdvoorspelling. Deze methodes maken geen gebruik van verkeerstromtheorie, maar gaan op zoek naar patronen in historische verkeersdata en andere relevante data en combineren deze met actuele gegevens. De methodes worden 'getraind' op een dataset en gevalideerd op een andere dataset. Er bestaat hierbij een risico van 'over fitting'. Dit wil zeggen dat het model meer parameters heeft dan nodig en daardoor heel goed aansluit op de trainingset, maar minder goed in staat is om voorspellingen te maken. Een regressiemodel is een voorbeeld van een datagedreven methode (van Hinsbergen and van Lint, 2008).

Zogenaamde ensemble methodes worden in toenemende mate gebruikt. Deze methodes combineren verschillende voorspelmethodes. De verschillende voorspelmethodes runnen tegelijkertijd en worden daarna gecombineerd tot één voorspelling. Dit kan bijvoorbeeld door de mediaan te kiezen en de twee meest extreme weg te laten, maar meer geavanceerde methode die de kwaliteit van de voorspelmethodes methodes toetsen op basis van de uitkomsten zijn ook mogelijk. Als bijvoorbeeld de bandbreedte van de voorspelling groot is, is de kwaliteit van de voorspelling lager.

## 2.3 *Realtime methodes*

Voor realtime verkeersmanagement, is het van belang dat bovengenoemde methodes 'realtime' en 'online' kunnen werken. Dit betekent dat ze een deel van hun input uit sensoren halen (zo actueel mogelijk) en die input gebruiken voor het maken van voorspellingen op basis waarvan de verkeersmanagementmaatregelen worden ingesteld/ingezet. De methodes moeten sneller dan realtime rekenen, omdat anders de voorspellingen alweer achterhaald zijn op het moment dat ze zijn berekend. De methodes moeten bovendien robuust zijn voor fouten in de input en sensoren die uitvallen. Er bestaan diverse methodes (bijvoorbeeld Chen et al., 2003) om de datakwaliteit te verbeteren. Daarnaast is het essentieel dat de modellen zelf betrouwbare resultaten genereren die bijvoorbeeld stabiel zijn over de tijd. In Vlahogianni et al.(2014) is een overzicht van realtime kortetermijnvoorspelmethodes opgenomen.

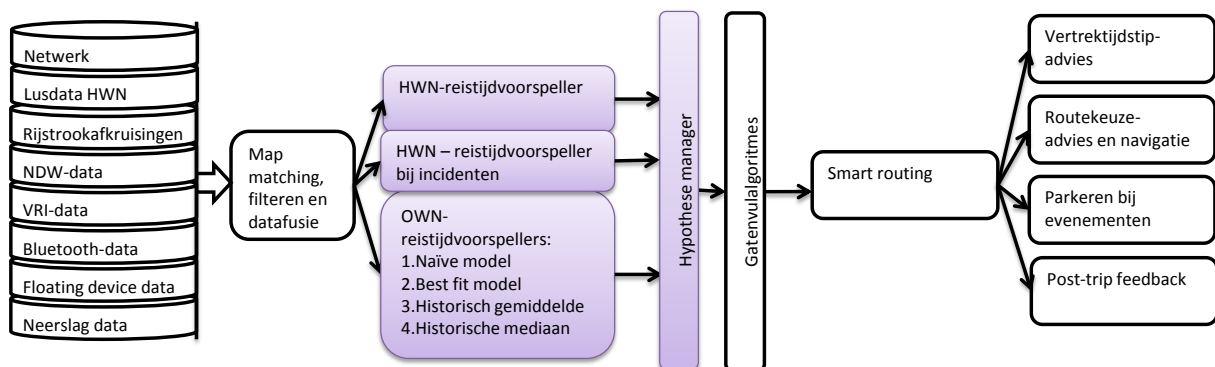
## **3. Raamwerk**

Dit artikel introduceert een raamwerk waarin meerdere datagedreven en op simulatie gebaseerde reistijdvoorspelmethodes zijn opgenomen en waarmee realtime iedere vijf minuten voorspellingen voor een groot realistisch wegennetwerk kunnen worden gemaakt tot 3 uur vooruit. Figuur 1 beschrijft de architectuur waarin de reistijdvoorspellers zijn opgenomen. Links staan de gebruikte databronnen. Deze databronnen bevatten historische data en de meest recente data van één of enkele minuten geleden. Met behulp van een map-matching algoritme wordt deze data gekoppeld aan een kaart, gefilterd en gefuseerd. Diverse reistijdvoorspellers draaien gelijktijdig op basis van deze data. De zogenaamde hypothesemanager combineert vervolgens de diverse reistijdvoorspellingen. De architectuur is zodanig opgezet dat eenvoudig andere reistijdvoorspellers kunnen worden toegevoegd en de kwaliteit van de

voorspellers die opgenomen zijn in het raamwerk kan worden gemonitord en verbeterd. Paragraaf 4 gaat nader in op de voor de Praktijkproef Amsterdam gebruikte voorspellers en de hypothesemanager.

Bovengenoemde stappen kunnen worden uitgevoerd voor wegvakken in het wegenetwerk waarvoor data van voldoende kwaliteit beschikbaar is. Het is echter ook essentieel om voor de onbemeten wegen reistijdvoorspellingen te genereren omdat anders al het verkeer over de onbemeten wegen wordt gestuurd. Daar wordt immers geen vertraging gemeten. Hiertoe zijn 'gatenvulalgoritmes' ontwikkeld. De volgende paragraaf gaat hier nader op in.

De reistijdvoorspellingen zijn de basis voor een slimme routeringsmodule (smart routing) waarmee vertrektijdadvies kan worden gegeven, routekeuze-advies kan worden gegeven welke wordt doorgegeven aan een navigatiemodule, advies over te kiezen parkeergarages bij evenementen kan worden gegeven en op basis waarvan de gebruiker feedback krijgt over de kwaliteit van het advies. Het vervolg van dit artikel richt zich op de paarse blokken uit figuur 1.

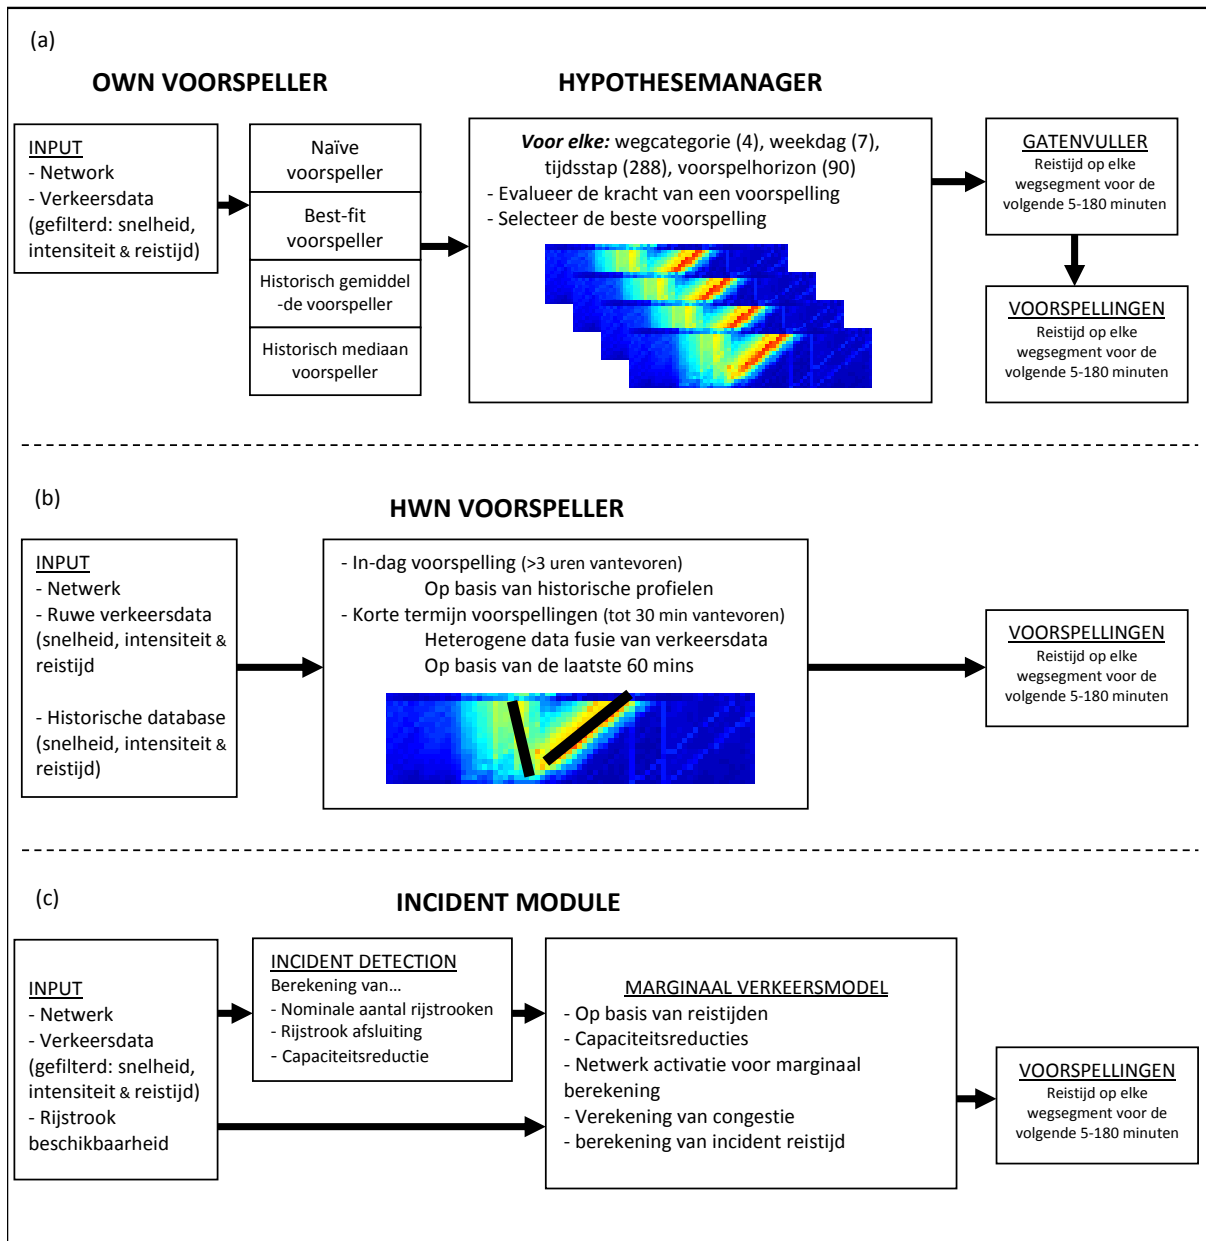


Figuur 1. Architectuur data en modellen

#### 4. Gebruikte reistijdvoorspellers in de Praktijkproef Amsterdam

Het gepresenteerde raamwerk is ontwikkeld voor de Praktijkproef Amsterdam, maar kan ook voor andere doeleinden worden ingezet. Voor regulier situaties is voor een combinatie van datagedreven-modellen gekozen omdat deze, mits vooraf getraind, een kortere rekentijd kennen en in ieder geval geen afwijkingen vertonen voor de actuele situatie. Voor incidentsituaties is een datagedreven methode minder geschikt omdat incidenten per definitie uitzonderlijk zijn en historische data dus geen goede basis biedt. Voor incidenten is daarom voor een marginaal model gekozen.

Figuur 2 beschrijft de voorspellers en hun in- en uitvoer op hoofdlijnen. Paragraaf 4.1 gaat nader in op de hypothesemanager en de OVN-voorspellers. Paragraaf 4.2 beschrijft de HWN-voorspeller en paragraaf 4.3 beschrijft het marginale incidentmodel voor snelwegen.



*Figuur 2. Invoer en uitvoer van de reistijdvoorspellers: a) OWN-voorspellers en hypothesemanager; b) HWN-voorspeller; c) marginale incidentmodule*

#### 4.1 Hypothesemanager en OWN-voorspellers

Zoals in paragraaf 2.1 is aangegeven bestaan er veel datagedreven methodes waarmee voorspellingen kunnen worden gemaakt op basis van historische en actuele data. De methodes richten zich meestal op specifieke omstandigheden (bijvoorbeeld snelwegen of lokale wegen, of reguliere situaties versus niet reguliere situaties etc.). Naar verwachting zal het combineren van verschillende methodes dus de beste resultaten opleveren. Het raamwerk dat in dit artikel wordt geïntroduceerd bevat daarom meerdere voorspellers die door de hypothesemanager worden gecombineerd tot één voorspelling (zie figuur 2a). Het raamwerk is zodanig opgezet dat het eenvoudig kan worden uitgebreid met andere voorspelmethodes.

Het raamwerk bevat vier voorspellers voor het onderliggende wegennetwerk (OWN-voorspellers). Gezien de vereiste korte rekentijd zijn de volgende vier eenvoudige en robuuste datagedreven methodes gekozen:

- Naïeve voorspeller: deze voorspeller veronderstelt dat de toekomstige situatie gelijk blijft aan de situatie in de vorige minuut. Zeker voor de zeer korte termijn is dit een goede veronderstelling.
- Best-fit voorspeller: deze voorspeller vergelijkt de situatie in de afgelopen T minuten (default 60 minuten) met de situatie in hetzelfde tijdsinterval in de afgelopen D dagen (default 100 dagen) en selecteert de dag die daar het meest op lijkt. De voorspelling wordt gebaseerd op de gerealiseerde verkeerssituatie op de geselecteerde dag.
- Historisch gemiddelde voorspeller: deze voorspeller kiest het gemiddelde van de afgelopen W weken (default 7 weken).
- Historische mediaan voorspeller: deze voorspeller kiest mediaan van de afgelopen W weken (default 7 weken).

Alle voorspellers maken onderscheid naar wegtype, dag van de week, tijd van de dag en voorspelhorizon.

De kwaliteit van de vier voorspellers is beoordeeld voor de het jaar 2013 op basis van data van het NDW. Bij de beoordeling van de kwaliteit is onderscheid gemaakt naar drie wegcategorieën: A (maximumsnelheid  $\geq 100$  km/uur), B (maximumsnelheid 70-80 km/uur) en C (maximumsnelheid  $\leq 50$  km/uur). A-wegen bevatten ook snelwegen waarvoor door de HWN-voorspeller ook een voorspelling wordt gemaakt (zie paragraaf 4.2). Daarnaast is onderscheid gemaakt naar de 7 dagen van de week, het tijdstip van de dag per interval van 5 minuten en de voorspelhorizon eveneens per interval van 5 minuten tot 3 uur vooruit. Voor iedere combinatie is de gemiddelde absolute fout berekend met formule 1. Hierin is  $P_i$  de voorspelde reistijd op wegvak  $i$  en  $R_i$  de gerealiseerde reistijd.  $N$  is het totaal aantal wegvak binnen de betreffende categorie.

$$E = \frac{\sum_{i=1}^N |P_i - R_i|}{\sum_{i=1}^N R_i} \quad (1)$$

Hoewel voor een groot deel van de A, B en C wegen data beschikbaar is, geldt dit niet voor alle wegen. Voor de onbemeten wegen wordt daarom via een 'gatenvul algoritme' een inschatting gemaakt van de reistijden. Dit algoritme werkt op basis van propagatie van verkeer en interpolatie van snelheidspatronen van een grote routeset. In totaal zijn ongeveer 1000 deels overlappende routes gegenereerd met behulp van het Dijkstra-algoritme voor kortste reistijden. Voor alle onbemeten wegen zijn alle routes geselecteerd die via de betreffende weg gaan. Aan maximaal 10 links van iedere route die wel bemeten zijn en die binnen 1,5 kilometer van de onbemeten weg liggen is een gewicht toegekend op basis van wegtype en de afstand tot de onbemeten weg. Met behulp van deze gewichten is een gewogen gemiddelde snelheid bepaald voor de onbemeten weg. Als onvoldoende routes aanwezig zijn, wordt de snelheid bepaald op basis van alle gemeten linksnelheden in een straal van 1,5 kilometer.

## 4.2 HWN-voorspeller

De voorspeller voor het hoofdwegennetwerk (HWN-voorspeller) (zie figuur 2b) wordt toegepast voor alle snelwegen waarvoor data van voldoende kwaliteit beschikbaar is. In de huidige versie worden de resultaten van de HWN-voorspeller altijd verkozen boven de resultaten van de OWN-voorspeller voor A-wegen indien data van voldoende kwaliteit voor de HWN-voorspeller beschikbaar is. Voor de snelwegen rondom Amsterdam worden dus twee voorspellingen gemaakt. Bij uitvallen van één van de databronnen is er dus altijd een terugvaloptie.

De snelwegen rond Amsterdam zijn vrijwel geheel bemeten met dubbele lussen die dicht bij elkaar liggen. De HWN-voorspeller maakt langetermijnvoorspellingen voor iedere dag van de week en kortetermijnvoorspellingen tot 3 uur vooruit.

De langetermijnvoorspellingen worden gebruikt voor verplaatsingen die één of meer dagen van te voren worden gepland. Deze voorspellingen zijn volledig gebaseerd op historische data. Hierbij wordt de mediaan gekozen van de vier vorige weken waarbij vakantiedagen eruit worden gefilterd.

Voorspellingen voor 15 minuten vooruit tot 3 uur vooruit worden op basis van een best-fit-voorspelling gemaakt. De kortetermijnvoorspelling voor 0 tot 15 minuten vooruit is gebaseerd op de methode zoals origineel beschreven in (Treiber and Helbing, 2002; Treiber et al., 2011; Van Lint and Hoogendoorn, 2010) en later aangepast voor snelle en efficiënte toepassing door (Schreiter et al., 2010; Van Lint, 2010). Bij deze methode wordt data van de afgelopen 60 minuten gebruikt. De verkeerspatronen (snelheden en intensiteiten) worden 30 minuten vooruit gepropageerd met behulp van 'kinematic wave theory' rekening houdend met de voorspelde verkeerssituatie over 15 minuten.

## 4.3 Marginaal incidentmodel

Datagedreven methodes ontleen hun succes aan het herkennen van patronen. Het voorspellen van onverwachte gebeurtenissen zoals incidenten en het effect daarvan is per definitie lastig op basis van datagedreven methodes omdat deze op willekeurige momenten gebeuren en een sterk wisselende impact hebben. Om deze reden is voor het voorspellen van de reistijd bij incidenten een realtime marginaal model ontwikkeld. Marginale modellen maken over het algemeen gebruik van de resultaten van een referentiemodelrun en passen vervolgens alleen de reistijden en intensiteiten van die delen van het netwerk aan die door worden beïnvloed door wijzigingen in de vraag of wijzigingen in het aanbod (zoals incidenten). Hierdoor hebben marginale modellen een korte rekentijd (Himpe and Tampère, 2013). Meer informatie over marginale modellen staat in (Corthout et al., 2014; Corthout et al., 2011; Himpe and Tampère, 2013). Het ontwikkelde realtime marginale model (zie figuur 2c) is een hybride model. Dit wil zeggen dat het zowel gedreven is door data als door verkeersstroomtheorie. Data met betrekking tot de actuele verkeerssituatie (intensiteiten, restcapaciteit en snelheden) is gebruikt als referentie 'modelrun'.



Incidenten worden gedetecteerd op basis van data over afgekruste rijstroken. Deze data is met een vertraging van minder dan 1 minuut beschikbaar. Afkruisingen als gevolg van plusstroken, spitsstroken, wisselstroken en wegwerkzaamheden worden uit deze data gefilterd. Op basis van het aantal afgekruste stroken en het wegtype wordt vervolgens met behulp van historische data van ongeveer 35 duizend incidenten een initiële duur en capaciteitsreductie van het incident geschat. Het model draait iedere minuut. De capaciteitsreductie wordt in de volgende minuut gekalibreerd op basis van de gemeten snelheden stroomopwaarts van het incident en de met het incidentmodel voorspelde snelheden.

Op basis van de gemeten verkeerssituatie en de capaciteitsreductie wordt met behulp van schokgolftheorie ('kinematic wave theorie') bepaald hoe snel de file achter het incident opbouwt en later weer afbouwt en welke wegen hierdoor worden beïnvloed. Op basis hiervan wordt de verwachte extra reistijd als gevolg van het incident berekend.

## **5. Praktijkproef Amsterdam**

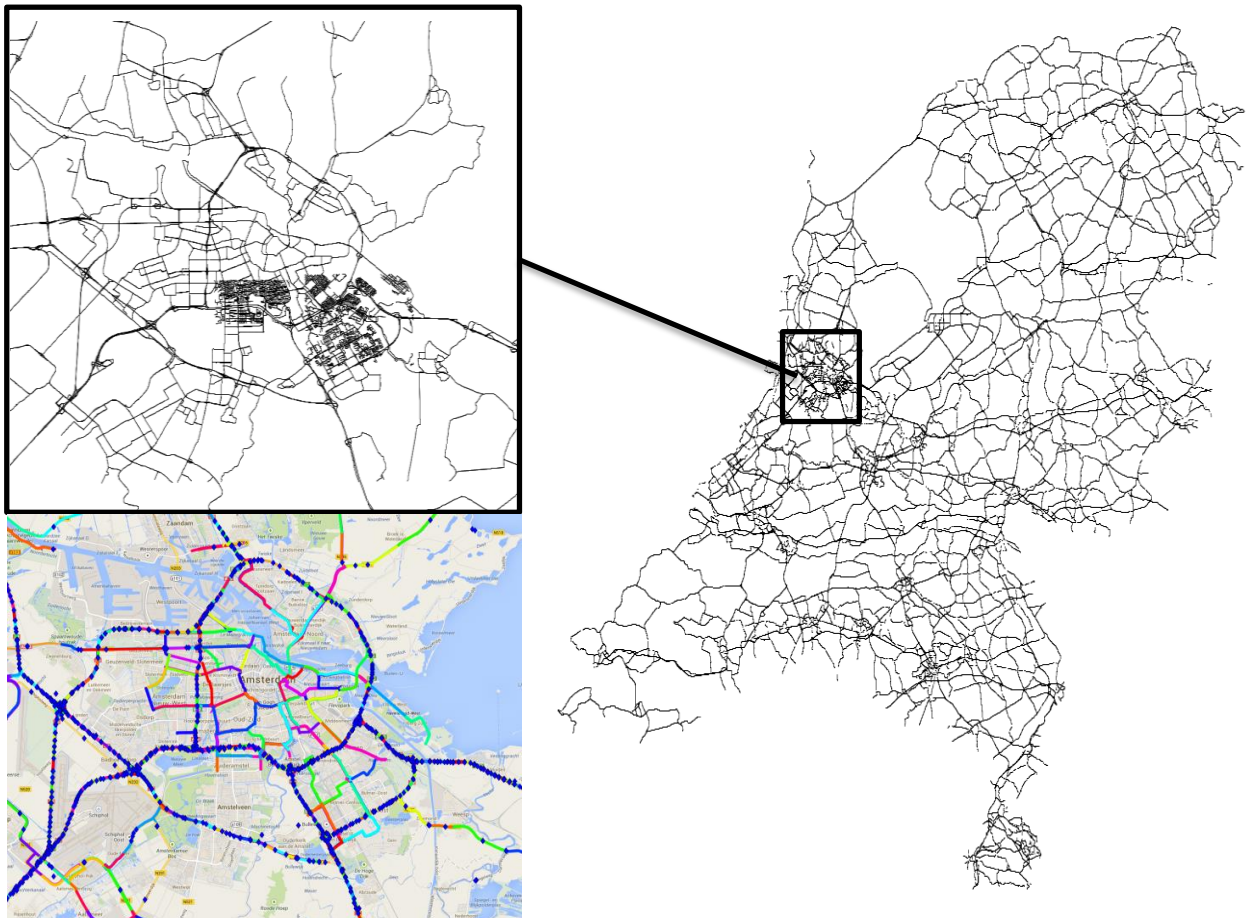
Deze paragraaf beschrijft hoe het raamwerk en een combinatie van korte termijnvoorspelmodellen in de Praktijkproef Amsterdam in het in-car spoor is ingezet met als doel om via gepersonaliseerde in-car informatie in Amsterdam en omgeving de voertuigverliesuren te beperken, de reistijdbetrouwbaarheid te vergroten en de bereikbaarheid te verbeteren.

### *5.1 Databronnen*

In figuur 3 is het netwerk weergegeven dat is gebruikt voor smart routing. Het netwerk bevat ongeveer 116 duizend links en 68 duizend knopen. Het netwerk bevat alle snelwegen en belangrijke andere wegen in Nederland. Rondom Amsterdam en in het bijzonder in de evenementengebieden rondom de Arena en de Rai bevat het netwerk een hoger detailniveau. Niet alle wegen in Nederland zijn dus in het netwerk opgenomen. Deze keuze is gemaakt om de rekentijd te beperken en, belangrijker nog, het routekeuze-advies te richten op de hoofdwegen. Voor de delen van de rit (eerste en laatste deel) die afgewikkeld worden op wegen die niet in dit netwerk zitten wordt gebruik gemaakt van standaard navigatiesoftware.

Voor het grootste deel van het hoofdwegennetwerk is historische en actuele (1 minuut vertraging in dataverwerking en maximaal 3 minuten vertraging in de live feed) lussdata (Ady-data) beschikbaar. Gemiddeld is de afstand tussen de lussen ongeveer 500 meter. Voor iedere minuut worden de gemiddelde snelheid (km/uur), de intensiteiten (voertuigen/uur), en de rijstrookafkruisingen opgeslagen. De Nationale Databank Wegverkeersgegevens (NDW) ontsluit historische en actuele data over reistijden en intensiteiten op snelwegen, secundaire wegen en de belangrijkste stedelijke wegen. De wegen waarvoor het NDW data ontsluit rondom Amsterdam zijn in figuur 3 links onderaan weergegeven (gekleurde links). Voor deze wegen zijn reistijden beschikbaar. Op de blauw gestippelde wegen (voornamelijk snelwegen) zijn ook intensiteiten beschikbaar.

Omdat de NDW-data minder gedetailleerd is dan de Ady-data gebruikt de HWN-voorspeller en het marginale incidentmodel de Ady-data. De OWN-voorspellers maken gebruik van de NDW-data. Naast de databronnen wordt gebruik gemaakt van additionele Bluetooth-sensoren die in de eventengebieden zijn geplaatst en van floating car data van Be-mobile en de PPA-app. Zoals eerder aangeven wordt ontbrekende data aangevuld met behulp van een 'gatenvulalgoritme'. Aangezien er steeds meer data beschikbaar komt, wordt de rol van het gatenvulalgoritme steeds onbelangrijker. Tot slot wordt gebruik gemaakt van actuele en voorspelde neerslagdata om de voorspelde reistijden voor het hoofdwegennetwerk bij te stellen op basis van relaties die per snelweg zijn vastgesteld tussen de neerslagintensiteit en de snelheidsreductie als gevolg van die neerslag.



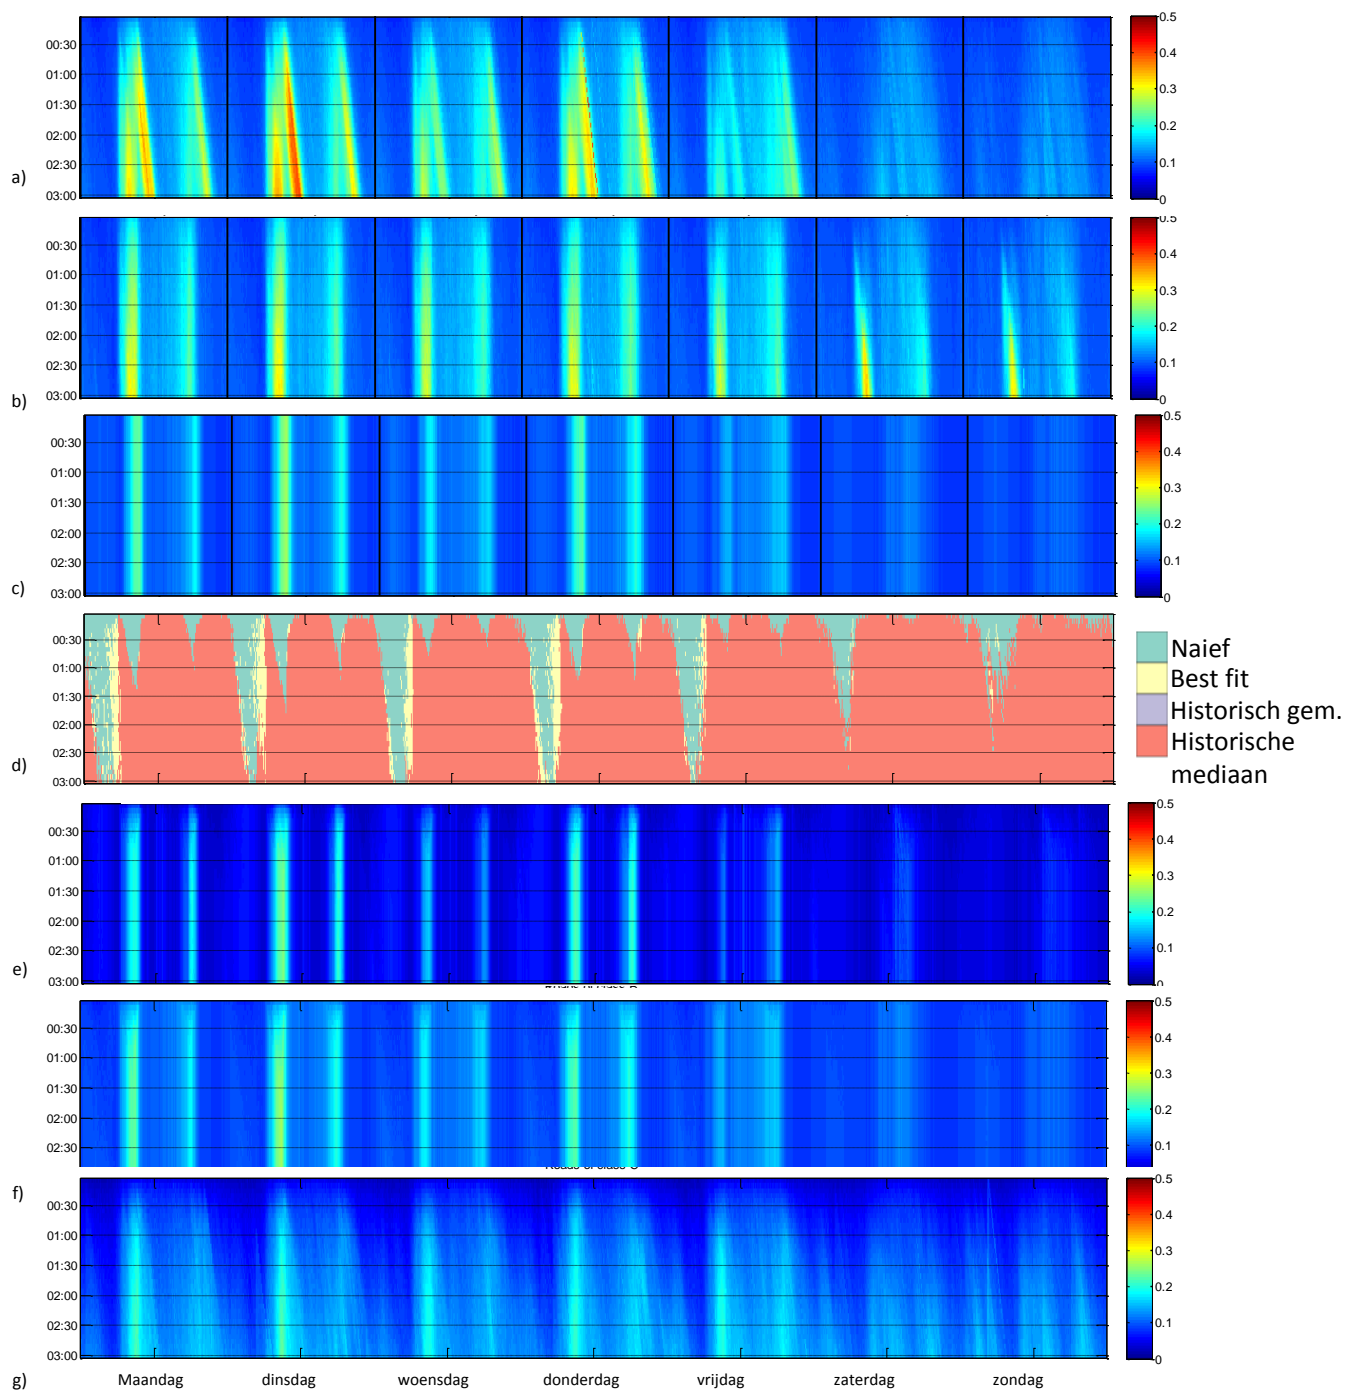
*Figuur 3. Wegennetwerk voor de Praktijkproef Amsterdam*

## 5.2 *Kwaliteit van de reistijdvoorspellers*

Figuur 4 a t/m c geeft een indicatie van de kwaliteit van de OWN-voorspellers op B-wegen. De B-wegen zijn de belangrijkste wegen voor de OWN-voorspellers. Op de y-as staat de voorspelhorizon: 0 tot 3 uur vooruit en op de x-as staan de verschillende dagen van de week. Per dag zijn alle 5-minuten intervallen van 0.00 uur (links) tot 23.55 uur (rechts) weergegeven. De kleur geeft de foutmaat aan die met formule 1 is berekend. Omdat de historische mediaan en het historische gemiddelde bijna gelijk scoorden is alleen de historische mediaan weergegeven. Uit de resultaten blijkt dat de naïeve

voorspeller goed scoort voor een korte voorspelhorizon tot soms 15 minuten vooruit. Dit is logisch omdat de verkeerssituatie in een paar minuten niet veel zal wijzigen. Voor zaterdag en zondag scoren zowel de naïeve voorspeller als de andere voorspellers goed. Deze dagen zijn over het algemeen congestievrij en dus makkelijk te voorspellen. Voor de langere termijn scoort de historische mediaan het beste. De best-fit voorspeller scoort het beste bij de overgang van daluren naar de spits. De hypothesemanager bepaalt uiteindelijk welke voorspeller wordt ingezet voor verschillende wegtypes, voor verschillende voorspelhorizonnen, voor verschillende dagen van de week en voor verschillende tijdstippen (zie figuur 4d).

Figuur 4e-g laat de foutmaat zien voor wegtype A, B en C op basis van de gecombineerde resultaten van de hypothesemanager. Voor de snelwegen (wegtype A) zijn de voorspellingen het meest nauwkeurig. De relatieve fout varieert over het algemeen tussen de 0% en de 20%. Op dinsdagen is de fout het in de ochtendspits het grootst. De kwaliteit van de voorspellingen is voor B-wegen iets lager dan de kwaliteit van de voorspellingen voor A-wegen. De fout blijft echter voor B-wegen over het algemeen onder 25%. Voor C-wegen is de fout vooral tijdens daluren groter. Dit blijkt veroorzaakt te worden door een slechte kwaliteit van de data op enkele wegen. De kwaliteit van de data wordt nog verbeterd.



Figuur 4. Per tijdstip, dag van de week en voorspelhorizon a) kwaliteit van de naïeve voorspeller; b) kwaliteit van de best-fit voorspeller; c) kwaliteit van de historische mediaan voorspeller; d) keuze van voorspeller; kwaliteit van de gecombineerde voorspeller op e) A, f) B en g) C wegen.

## 6. Conclusies en aanbevelingen

In dit artikel is een raamwerk voor realtime reistijdvoorspelling gepresenteerd waarbij een combinatie van voorspellers gelijktijdig draaien. In het artikel is aangetoond dat dit een goede keuze is omdat verschillende methodes in verschillende situaties goed scoren. Voor de Praktijkproef Amsterdam zijn vier OWN-voorspellers ingezet. De naïeve voorspeller scoorde het best voor een korte voorspelhorizon (tot 15 minuten vooruit) en voor situaties zonder congestie. De best-fit voorspeller scoort het best bij de overgang naar spitsperiodes en de historische mediaan voorspeller scoort het best gedurende de overige periodes. Op basis van de resultaten kan geconcludeerd worden dat deze eenvoudige voorspelmethodes al goed presteren, omdat de relatieve fout over het algemeen kleiner is dan 20%. Het voordeel van het gepresenteerde raamwerk is dat het eenvoudig is om nieuwe meer geavanceerde methodes toe te voegen. Met behulp van de geïntroduceerde hypothesemanager kunnen de verschillende voorspellingen worden gecombineerd tot één voorspelling.

De gekozen voorspelmethodes zijn voornamelijk datagedreven methodes. Deze keuze is gemaakt om kalibratieproblemen te beperken en omdat deze methodes over het algemeen een kortere rekentijd hebben dan simulatiemethodes. Uiteraard moeten de parameters van de datagedreven methodes ook worden gekalibreerd, maar dit kan offline worden gedaan wat eenvoudiger is dan het realtime schatten van herkomstbestemmingsmatrices die voor de meeste simulatiemodellen nodig zijn. Daarnaast is de actuele verkeerssituatie waar datagedreven methodes van uitgaan per definitie correct (zolang de data correct is). Bij simulatiemodellen wijkt de actuele situatie al direct af van de praktijk.

Naast de bestaande datagedreven voorspelmethodes is in dit artikel een nieuw hybride realtime marginaal incidentmodel geïntroduceerd. Hybride wil zeggen dat gebruik wordt gemaakt van data voor de actuele situatie en op basis van verkeerstromtheorie de marginale veranderingen in de verkeerssituatie als gevolg van een incident worden berekend. Het model wordt realtime gekalibreerd. De resultaten van dit model worden in een apart artikel gepubliceerd.

Tot slot: de Praktijkproef Amsterdam heeft aangetoond dat het geïntroduceerde raamwerk het mogelijk maakt om binnen 1 minuut kwalitatief hoogwaardige voorspellingen voor een groot netwerk (116 duizend links en 68 duizend knopen) te maken op basis van grote hoeveelheden data.

Een vervolgstap richt zich op het flexibiliseren van de hypothesemanager door de keuze voor een voorspelmethode niet alleen van de historische prestaties af te laten hangen, maar ook van lokale recente/actuele data.

## Dankwoord

Dit werk is gesponsord door de Praktijkproef Amsterdam (PPA) en gezamenlijk door TNO, ARS en PrimeData uitgevoerd. De auteurs willen in het bijzonder Taoufik Bakri, Bjorn Heijligers, Jasper van Huis, Michiel Minderhoud, Isabel Wilmink, Ernst Jan van Ark, Marco Duijnisveld en Bas van den Heuvel en Victor Knoop bedanken voor hun bijdrages.

## Referenties

- Calvert, S., Snelder, M., Bakri, T., Heijligers, B. and Knoop, V.L., 2015. Real-Time Travel Time Prediction Framework for Departure Time and Route Advice. In *94th Annual Meeting of the Transportation Research Board*.
- Chen, C., Kwon, J., Rice, J., Skabardonis, A. and Varaiya, P., 2003. Detecting errors and imputing missing data for single-loop surveillance systems. *Transportation Research Record: Journal of the Transportation Research Board*, 1855(1), pp.160–167.
- Corthout, R., Himpe, W., Viti, F., Frederix, R. and Tampere, C.M.J., 2014. Improving the efficiency of repeated dynamic network loading through marginal simulation. *Transportation Research Part C: Emerging Technologies*, 41, pp.90–109.
- Corthout, R., Tampère, C.M.J., Frederix, R. and Immers, L.H., 2011. Marginal dynamic network loading for large-scale simulation-based applications. In *Transportation Research Board 90th Annual Meeting*.
- Daganzo, C.F., 1995. The cell transmission model, part II: network traffic. *Transportation Research Part B: Methodological*, 29(2), pp.79–93.
- Daganzo, C.F., 1994. The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory. *Transportation Research Part B: Methodological*, 28(4), pp.269–287.
- Himpe, W. and Tampère, C., 2013. Efficient Dynamic Network Loading Modeling: The fixed point link transmission model. *BIVEC-GIBET Transport Research Day*, pp.95–98.
- Van Hinsbergen, C.P.I.J. and van Lint, J.W.C., 2008. Bayesian combination of travel time prediction models. *Transportation Research Record: Journal of the Transportation Research Board*, 2064(1), pp.73–80.
- Knoop, V.L., van Lint, J.W.C., Vries, J., Kester, L. and Passchier, I., 2013. Relationship between application scale and maximum time latency in Intelligent Transport Solutions. *Transportation Research Record: Journal of the Transportation Research Board*, 2380(1), pp.1–9.
- Van Lint, J.W.C., 2010. Empirical evaluation of new robust travel time estimation algorithms. *Transportation Research Record: Journal of the Transportation Research Board*, 2160(1), pp.50–59.
- Van Lint, J.W.C. and Hoogendoorn, S.P., 2010. A robust and efficient method for fusing heterogeneous data from traffic sensors on freeways. *Computer-Aided Civil and Infrastructure Engineering*, 25(8), pp.596–612.
- Schreiter, T., van Lint, H., Treiber, M. and Hoogendoorn, S., 2010. Two fast implementations of the Adaptive Smoothing Method used in highway traffic state estimation. In *Intelligent Transportation Systems (ITSC), 2010 13th International IEEE Conference on*. IEEE, pp. 1202–1208.

- Tampère, C.M.J., Corthout, R., Cattrysse, D. and Immers, L.H., 2011. A generic class of first order node models for dynamic macroscopic simulation of traffic flows. *Transportation Research Part B: Methodological*, 45, pp.289–309.
- Treiber, M. and Helbing, D., 2002. Reconstructing the spatio-temporal traffic dynamics from stationary detector data. *Cooperative Transportation Dynamics*, 1(3), pp.3.1–3.21.
- Treiber, M., Kesting, A. and Wilson, R.E., 2011. Reconstructing the traffic state by fusion of heterogeneous data. *Computer-Aided Civil and Infrastructure Engineering*, 26(6), pp.408–419.
- Vlahogianni, E.I., Karlaftis, M.G. and Golias, J.C., 2014. Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*.
- Yperman, I., 2007. The Link Transmission Model for dynamic network loading. *Ph.D. Thesis, Katholieke Universiteit Leuven*.