

Korte termijn voorspelling van de verkeerstoestand

Henri Palm – DAT.Mobility – hpalm@dat.nl

Luc Wismans – DAT.Mobility – lwismans@dat.nl

Paul van Beek – Goudappel Coffeng – pvbeek@goudappel.nl

Bijdrage aan het Colloquium Vervoersplanologisch Speurwerk 23 en 24 november 2017, Gent

Samenvatting

Operators van stedelijke, regionale en landelijke verkeerscentrales zijn er bij gebaat dat zij een goed en actueel beeld van het verkeer hebben. Hierdoor zijn ze beter in staat om incidenten sneller op te sporen en in een vroeg stadium inzicht te krijgen in huidige en toekomstige locaties en ernst van files. Deze informatie biedt de mogelijkheid om niet alleen sneller te anticiperen maar ook pro-actief te reageren en daardoor congestieproblemen te verminderen met behulp van verkeersmanagementmaatregelen. Echter, deze zelfde informatie kan ook zeer bruikbaar zijn voor nieuwe of geautomatiseerde intelligente transport systemen zowel wegkantsystemen, maar juist ook in het voertuig.

De kwaliteit en beschikbaarheid van verkeersgegevens is de afgelopen jaren aanzienlijk verbeterd. Steeds meer komen lsdetectorgegevens, intensiteiten bij VRI's en floating car data real time beschikbaar. Niet alleen voor het hoofdwegennet maar ook voor het onderliggend wegennet beschikken we over steeds betere en actuelere gegevens. De latency, de tijd tussen inwinning en verstrekking van de gegevens, wordt daarbij steeds korter: was eerst nog sprake van minuten latency, nu spreken we van seconden. Deze toename aan beschikbare real time data opent de mogelijkheid om een steeds beter beeld te krijgen van de huidige toestand op de weg. Echter, diezelfde data kunnen al dan niet in combinatie met modeltechnieken ook worden gebruikt om met een grotere betrouwbaarheid korte termijn voorspellingen te maken van deze toestand.

Dit paper gaat over de ontwikkeling van een korte-termijnvoorspeller van de verkeerstoestand voor snelwegen en niet snelwegen en de kwaliteit er van door toepassing binnen twee cases in de praktijk. In de basis levert de voorspeller informatie over de actuele toestand voor het complete wegennet, een voorspelling van de toestand over 10 minuten en gedetecteerde incidenten (onverwachte afwijkingen). Dit paper beschrijft een model gebaseerde real-time korte-termijnvoorspeller en behaalde resultaten voor twee pilotgebieden: snelwegring A10 Amsterdam en een netwerkstreng in Almere. Deze zijn uitgevoerd binnen de programma's van respectievelijk CHARM en iCentrale.

De resultaten zijn hoopvol. Incidenten worden snel en goed gedetecteerd. De korte termijn voorspelling van de verkeerstoestand over 10 minuten is in circa 90% van de gevallen correct.

1. Waarom korte termijn voorspelling?

Operationeel verkeersmanagement voor autosnelwegen is in Nederland reeds ver ontwikkeld. Dit komt mede doordat er relatief veel (real time) data voor het hoofdwegennet beschikbaar is door het uitgebreide netwerk van lsdetectoren. De beschikbaarheid van real time data zal zelfs verder toenemen, mede door de technologische ontwikkelingen die in de automotive industrie en als gevolg van het gebruik van smartphones gaande zijn. Op verschillende fronten lopen initiatieven om met deze informatie intelligente diensten op te ontwikkelen. In programma's zoals Beter Benutten Vervolg-ITS en Data Top 8, CHARM, iCentrale en Talking Traffic zijn de (landelijke) overheid, industrie en marktpartijen bezig om innovaties van de grond te krijgen en in diensten uit te rollen. Allemaal met als doel een betere doorstroming op de weg te krijgen.

Ook voor stedelijke omgevingen komen door de inzet van slimmere VRI's en door ruimere beschikbaarheid van floating car data (FCD) steeds meer bruikbare informatie beschikbaar. Deze data worden bovendien steeds beter en komt steeds sneller beschikbaar. Ervaringen met bijvoorbeeld het gebruik van data uit VRI's (streaming VLOG) laten zien hoe nuttig dat kan zijn: stedelijke operators kunnen gelijk ingrijpen op het moment dat het ergens mis gaat [1]. Dat ingrijpen kan bestaan uit bijvoorbeeld het sturen van hulpdiensten, het aanpassen van VRI-regelingen of het aansturen van DRIPs.

Deze toename aan beschikbare real time data opent de mogelijkheid om een steeds beter beeld te krijgen van de huidige toestand op de weg. Echter diezelfde data kunnen al dan niet in combinatie met modeltechnieken ook worden gebruikt om met een grotere betrouwbaarheid korte termijn voorspellingen te maken van deze toestand. Dergelijke informatie stelt operators in een verkeerscentrale in staat om incidenten sneller op te sporen en in een vroeg stadium inzicht te krijgen in huidige en toekomstige locaties en ernst van files. Deze informatie biedt de mogelijkheid om niet alleen sneller te anticiperen maar ook pro-actief te reageren en daardoor congestieproblemen te verminderen met behulp van verkeersmanagementmaatregelen. Echter, deze zelfde informatie kan ook zeer bruikbaar zijn voor nieuwe of geautomatiseerde intelligente transport systemen zowel wegkantsystemen, maar juist ook in het voertuig. Dit paper gaat over de ontwikkeling van een korte-termijnvoorspeller van de verkeersstoestand voor snelwegen en niet snelwegen en de kwaliteit er van door toepassing binnen twee cases in de praktijk. In de basis levert de voorspeller informatie over de actuele toestand voor het complete wegennet, een voorspelling van de toestand over 10 minuten en gedetecteerde incidenten (onverwachte afwijkingen).

Dit paper is als volgt opgebouwd. In hoofdstuk 2 wordt de werking uitgelegd. De resultaten van twee toepassingen worden in hoofdstuk 3 beschreven. Conclusies over de kwaliteit en hoe verder staan in hoofdstuk 4.

2. Hoe werkt de korte-termijnvoorspeller?

In dit hoofdstuk wordt uitgelegd uit welke onderdelen de korte-termijnvoorspeller is opgebouwd en hoe die met elkaar samenwerken.

2.1 Combinatie van data en model driven

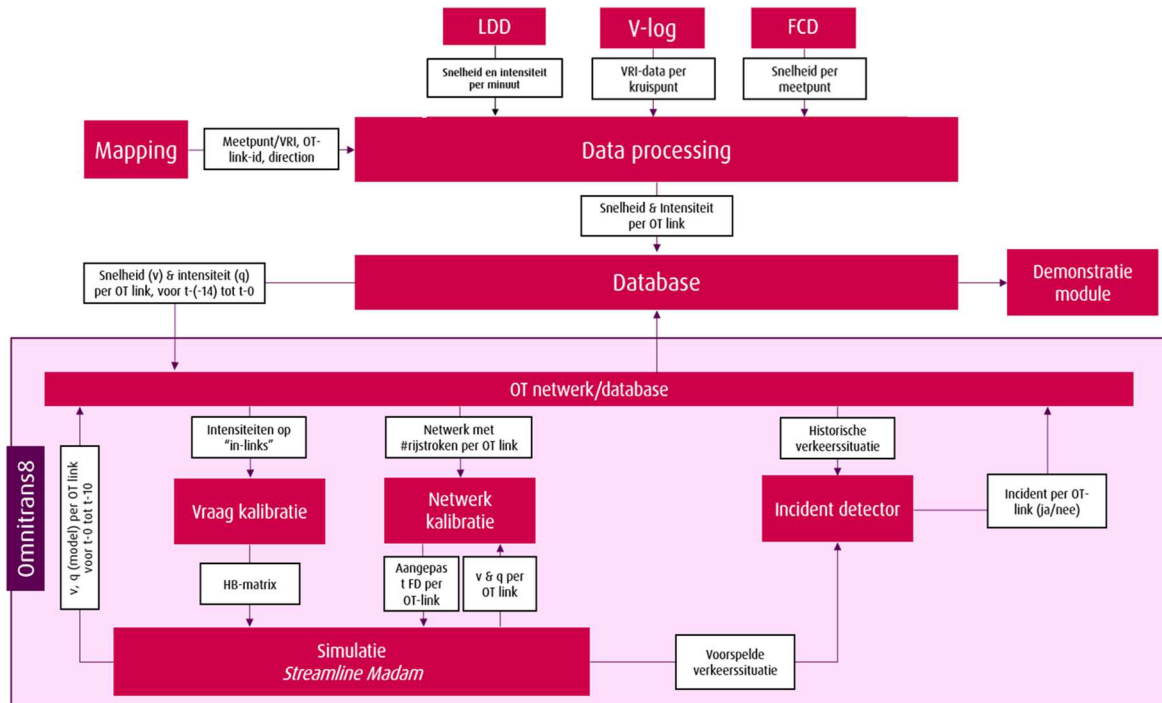
Er zijn verschillende benaderingen om de verkeersstoestand op de korte termijn te voorspellen. Van Hinsbergen [2] geeft een overzicht van the-state-of-art korte-termijnvoorspelmethode. Op hoofdlijnen wordt onderscheid gemaakt tussen naïeve, parametrische en niet-parametrische methoden of hybride vormen. Binnen deze methoden zijn weer tal van specifieke methoden ontwikkeld. In de basis verschillen deze uit of methoden puur gebaseerd op beschikbare en gemeten data of methoden waarbij deze worden gecombineerd met verkeersmodelalgoritme. Uit hun evaluatie van al deze methoden springt er niet een duidelijk uit als de beste voor alle situaties of alle gewenste indicatoren om de verkeersstoestand vast te leggen (denk bijvoorbeeld aan reistijden op relaties versus snelheden op ieder individueel wegvak). De uitdaging is om de modellen in de praktijk uit te proberen.

De methodiek die we voor ogen hebben, moest in staat zijn om voor een compleet netwerk op segmenten met een typische lengte van 50-300 m de afwikkeling te beschrijven, waardoor tevens file locaties en file lengtes afgeleid konden worden en waarbij het mogelijk zou zijn om incidenten te kunnen detecteren. Op basis van onze bevindingen uit de eerste fasen van CHARM waarin een geschikte aanpak is onderzocht en getest hebben wij uiteindelijk gekozen voor een concrete toepassing van een methodiek waarbij een macroscopisch dynamisch verkeersmodel dat wordt gevoed met zoveel mogelijk (real time) data. De voordelen van deze aanpak zijn:

- Door het model en netwerkbenadering zijn de verkeersstoelstanden in het netwerk onderling consistent met een theoretische verkeerskundig gezonde basis.
- Ook voor niet-bemeten wegvakken is de huidige verkeersstoestand (weliswaar op basis van de combinatie van wel bemeten wegvakken en modelberekeningen) bekend.
- Het model kan voorspellingen leveren voor alle tussenliggende tijdsperioden en biedt bovendien de mogelijkheid om aanvullende verkeerskundige indicatoren af te leiden zonder dat hiervoor een nieuwe data-gedreven methode voor hoeft te worden getraind.
- Er kan goed worden omgegaan met niet reguliere zaken (denk aan weersomstandigheden, groot evenement of zelfs inzet van maatregelen) als gevolg van geautomatiseerde kalibratie van zowel vervoersvraag als infrastructuur aanbod, zonder dat hiervoor aanvullende databronnen noodzakelijk zijn.
- Er bestaat de mogelijkheid om 'What-if scenario's' door te rekenen en daarmee de inzet van maatregeleninzet te optimaliseren.
- Het verschil tussen gemodelleerd en gemeten is aanvullende informatie (bijvoorbeeld een groot verschil tussen beiden duidt op een onverwacht incident).

Het raamwerk waaruit de korte-termijnvoorspellingsmodule is opgebouwd staat in figuur 2.1. Als eerste wordt ruwe data van verschillende bronnen in de data processing component gefuseerd tot een homogene dataset, die als basis kan dienen voor verdere verwerking. Deze data wordt weggeschreven in een centrale database van waaruit de data worden gecommuniceerd van en naar een simulatieomgeving en de demonstratiemodule. De simulatieomgeving is vervolgens verantwoordelijk voor de daadwerkelijke verkeersmodellering inclusief incident detectie en predictie. De simulatieomgeving betreft een macroscopische modelomgeving binnen Omnitrans8,

waarbinnen korte-termijnverkeersprognoses worden uitgevoerd met behulp van het dynamische toedelingmethodiek StreamLine::Madam. Intelligente algoritmes met betrekking tot vraagkalibratie, netwerkcalibratie en incident detectie zijn verantwoordelijk voor het uiteindelijke resultaat.



Figuur 2.1: raamwerk korte-termijnvoorspeller

Hierna wordt eerst het dataproces en vervolgens de verkeersmodellering toegelicht.

2.2 Het dataproces

De datamodule is verantwoordelijk voor het onttrekken en ontvangen van ruwe, real-time data uit verschillende bronnen: lusdata met intensiteiten en snelheden, floating car data (FCD) en lusdata bij VRI's (specifiek VLOG-data). De ruwe gegevens worden achtereenvolgens:

- gefilterd (vreemde waarden, geen waarden);
- geaggregeerd (bijvoorbeeld van rijstrook naar rijbaan);
- gemapt aan linksegmenten van het netwerk voor de verkeersmodellering;
- gesynchroniseerd (in verband met verschillen in tijdstempels en latency);
- gefuseerd daar waar meerdere bronnen voor een wegvak dezelfde grootheden levert (bijvoorbeeld snelheden uit lusdata en FCD).

De data worden weggeschreven in een centrale database van waaruit de data worden gecommuniceerd naar de module voor de verkeersmodellering. De resultaten van de verkeersmodellering, intensiteiten en snelheden voor de komende minuten, worden ook in de centrale database opgenomen. Op de centrale database is een demonstratiemodule aangesloten om de resultaten via een Graphical User Interface (GUI) geografisch te visualiseren.

Voor het functioneren van de incident detectie en predictie module is een netwerk benodigd. Dit netwerk dient allereerst als basis voor de simulatieomgeving waarbinnen de predictie en detectie wordt uitgevoerd, maar biedt daarnaast ook de basis voor de dataverzameling. Verzamelde data wordt gekoppeld aan het gehanteerde netwerk door deze te mappen aan linksegmenten en kruispunten. Hiermee wordt niet alleen het model van inputdata voorzien, maar dit biedt eveneens de mogelijkheid om data van verschillende databronnen op een eenduidige manier in één omgeving te visualiseren

2.3 Het modelleringsproces

De verkeersmodellering bestaat uit een combinatie van een viertal submodules die integraal en real time aan het rekenen zijn. De submodules worden hierna toegelicht.

Kalibratie vervoervraag

De gemeten intensiteiten uit lussen op wegvakken of bij VRI's (VLOG-data) vormen de basis voor de vervoersvraagkalibratie. Uit de VLOG-data worden intensiteiten afgeleid op de verschillende kruispunten op het netwerk. Om het effect van VRI-cyclussen niet extreem terug te zien in de afgeleide intensiteiten is gekozen om gebruik te maken van een lopend gemiddelde over 5 minuten. Vervolgens worden deze intensiteiten aan de betreffende netwerklinks gekoppeld. De netwerklinks aan de randen van het netwerk vormen de zogenaamde in-links. Op basis van de intensiteiten op deze in-links wordt de HB-matrices per tijdsperiode (bijvoorbeeld per minuut) voor het netwerk gekalibreerd zodat de vervoersvraag die op het netwerk wordt gezet, overeenkomt met de gemeten waarden.

Kalibratie netwerk

Vertraging of congestievorming kan verschillende oorzaken hebben. Zo kan bijvoorbeeld het lokale verkeersaanbod groter zijn dan de capaciteit van een bepaalde wegconfiguratie. Echter juist deze capaciteit kan onderhevig zijn aan verschillende (exogene) invloeden zoals het weer of het afkruisen van een strook door een operator. Het gedrag van verkeer mede als gevolg van de netwerkkarakteristieken wordt in het model beschreven door een fundamenteel diagram. Door het fundamenteel diagram continue te kalibreren op basis van metingen worden deze invloeden voortdurend meegenomen in onze aanpak. Op netwerken met niet of nauwelijks kruispunten, zoals bijvoorbeeld autosnelwegen kan de vertraging op links vrijwel volledig worden verklaard binnen deze fundamentele diagrammen. Op stedelijk wegennet komt hier echter een complicerende factor bij kijken in de vorm van kruispunten. Hierdoor zijn op dergelijke netwerken vaak niet wegvak-, maar kruispuntcapaciteiten de oorzaak voor vertragingen op het netwerk. Het effect van deze kruispunten wordt op een kunstmatige wijze in het verkeersmodel gekalibreerd. Op iedere kruispunttak wordt op het benedenstroomse wegvak het fundamenteel diagram op een dergelijke manier aangepast dat de capaciteit van dit wegvak overeenkomt met de capaciteit van de desbetreffende tak op het kruispunt.

Methodisch werkt de kalibratie als volgt. Nadat de vervoersvraag is gekalibreerd kan het verkeer aan het netwerk worden toegedeeld. Hoewel de vervoersvraag en routing op het netwerk nu in overeenstemming is gebracht met de gemeten waarden, komen de netwerksnelheden op het netwerk nog niet overeen met de beschikbare gemeten (en

gefuseerde) snelheden. Daarom zorgt de netwerkkalibratie ervoor dat het netwerk zo worden gekalibreerd dat een toedeling resulteert in netwerksnelheden conform deze gemeten snelheden (en dus ook conform de daadwerkelijk gerealiseerde snelheden). Gedurende de kalibratieperiode worden wegvak- en kruispuntcapaciteiten voortdurend opnieuw bepaald. Dit gebeurt op basis van een vergelijking tussen gerealiseerde modelsnelheden en gemeten FCD-snelheden in de reeds gepasseerde periode.

StreamLine::Madam

StreamLine::MADAM is een macroscopisch toedelingsmodel dat verkeersaanbod op HB-relaties vertaalt naar verkeersintensiteiten, snelheden en dichtheden op linkniveau over tijd en ruimte. Het is consistent met verkeerstromtheorie (zie [3]). De output van StreamLine::MADAM bestaat uit intensiteiten, snelheden en dichtheden voor individuele segmenten op een geselecteerd netwerk. Deze waarden worden bepaald voor zowel de actuele als de predictieperiode. De StreamLine::MADAM submodule bestaat uit verschillende stappen, die hierna worden beschreven en continue worden doorlopen. Hoewel de diverse tijdselementen instelbaar zijn, beschrijven we een methodiek waarbij we 10 minuten vooruit ($t+10$) voorspellen en een kalibratie van een voorlooperperiode aanhouden van tevens 10 minuten. Dat betekent dat iedere cyclus van een korte termijn voorspelling voor over 10 minuten start met een simulatie op een tijdstip 10 minuten voor de huidige tijdstap ($t-10$).

Stap 1: Instellen van initiële verkeerscondities

De eerste stap is om de initiële verkeerscondities op het netwerk toe te delen zodat snelheden, intensiteiten en dichtheden in de modelomgeving overeenkomstig de daadwerkelijke situatie zijn. Hiervoor wordt in deze toepassing gebruik gemaakt van een warme start. In feite wordt voor de initiële verkeerscondities het resultaat gebruikt van eerdere uitkomsten voor de start van de simulatie periode (gebaseerd op resultaat van stap 3). De verkeerscondities worden als het ware gekopieerd vanuit deze eerdere simulatierun naar de start van de kalibratieperiode van de nieuwe run.

Stap 2: Kalibratieperiode

Zodra de initiële verkeerscondities op het netwerk zijn gezet, propageert StreamLine::MADAM het verkeer over een periode van 10 minuten. Deze eerste 10 minuten zijn daarbij de kalibratie periode, waarvoor dus ook de metingen reeds beschikbaar zijn. Gedurende die eerste 10 minuten wordt de kalibratie uitgevoerd conform de voorgaande toelichting en eindigt dus op tijdstip van de huidige situatie (t_0). De nieuwe waarden voor alle fundamentele diagrammen vormen tevens weer input voor een volgende run waarin een nieuwe kalibratieslag zal plaatsvinden.

Stap 3: Opslaan verkeersconditie op t_0

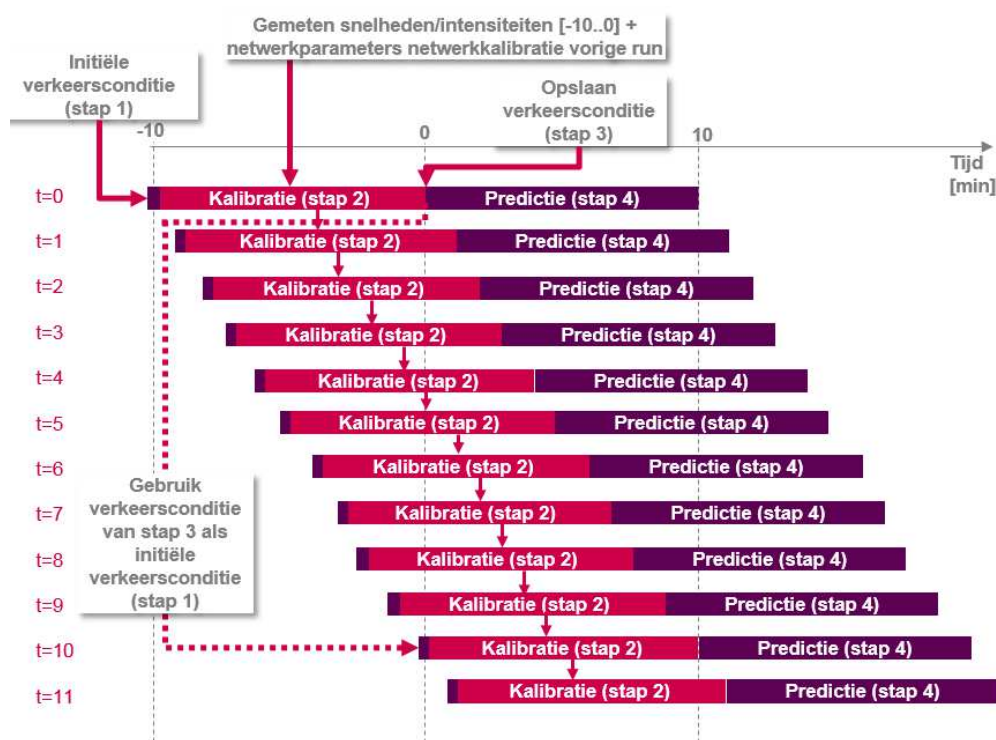
De verkeersconditie op t_0 wordt opgeslagen, zodat deze over tien minuten als warme start kan fungeren (stap 1) voor een nieuwe kalibratieperiode. Dezelfde kopie van de verkeerscondities is de basis voor de simulatie van de predictieperiode. Optioneel kan er in deze stap tevens voor worden gekozen om de gemodelleerde verkeerstoestand voor de wegvakken die bemeten zijn, te overschrijven met de metingen, zodat de situatie op t_0 nog beter overeenkomt

met de metingen. In de implementatie hebben we dit voorsnog niet gedaan ten behoeve van de evaluatie van de kwaliteit van de methodiek.

Stap 4: Predictie periode

Vergelijkbaar aan stap 2 propageert StreamLine::MADAM het verkeer over predictieperiode van tien minuten mede op basis van de gekalibreerde vervoersvraag (eerder beschreven) en netwerkcalibratie van stap 2. De module produceert de verkeersconditie voor iedere link in het netwerk voor iedere predictie minuut.

In figuur 2.2 is het modelleringsproces nog eens geschematiseerd.



Figuur 2.2: Modelleringsproces in de tijd

Congestieschatter & Incident detectie

Op basis van de simulatieresultaten en gemeten data is een virtual patrol ontwikkeld die enerzijds schat of er sprake is van congestie en anderzijds of er zich waarschijnlijk een incident heeft voorgedaan. De congestieschatter verwerkt zowel de output data van StreamLine::MADAM als de gemeten data. Om te bepalen of er sprake is van congestie op het netwerk (en of deze congestie redelijkerwijs te verwachten had kunnen zijn of dat deze volledig onverwacht optreedt), bepaalt de congestieschatter een mate van congestie voor ieder wegvak voor ieder tijdstip (voor zowel t_0 als voor de predictieperiode). Deze mate van congestie wordt uitgedrukt in een congestiefactor met een waarde tussen de 0 en de 1 op basis van fuzzy logic. De positie van een meting of modelwaarde in het fundamenteel diagram van de desbetreffende link bepaalt daarbij de mate van congestie van de link. Hierin speelt voornamelijk de snelheid een belangrijke rol. Wanneer een snelheid wordt gemodelleerd die ver onder de 'free flow'-snelheid ligt,


valt met grotere zekerheid te zeggen dat er sprake is van congestie dan wanneer er slechts weinig verschil met de 'free flow'-snelheid is. In dit laatste geval is het waarschijnlijker dat er geen sprake is van congestie. De mate van congestie wordt tevens meegenomen in het algoritme dat verantwoordelijk is voor de incident detectie.

De incident detectie werkt op basis van een vergelijking tussen de toestand volgens de gemeten data op een segment en in het verleden voorspelde toestand op dat segment. De predictiemodule levert niet alleen de voorspelling van de toestand over 10 minuten, maar levert ook een predictie voor alle tussenliggende minuten. Daarin zit dus ook de verwachting voor over 1 minuut ($t+1$). Bovendien herhaalt dat predictieproces zich iedere minuut. Zodra de meting van de nieuwe minuut beschikbaar is, kan deze direct worden vergeleken met de verwachting voor die minuut. Grote verschillen waarbij de meting sterk afwijkt van de verwachting kan duiden op een incident of probleem in het netwerk. Er zijn fuzzy logic regels ontwikkeld om op basis van de verschillen tussen meting en verwachting de 'kans dat er sprake is van een incident' te bepalen. Indien de werkelijke snelheden ook voor de daarop volgende minuut weer sterk afwijken, meting is lager dan verwachting, dan wordt de kans dat er sprake is van een incident weer groter.


3. Hoe goed werkt de korte termijn voorspeller?

3.1 Een tweetal toepassingen

De korte termijn voorspeller is geïmplementeerd in twee pilotgebieden (zie figuren 3.1 en 3.2). Deze pilots komen uit twee programma's waar deze korte termijn voorspeller is ontwikkeld en geïmplementeerd, namelijk CHARM en iCentrale. Het CHARM-programma, een samenwerking tussen Highways England (UK) en Rijkswaterstaat (NL), is gericht op het innoveren van verkeersmanagementcentrales voor het hoofdwegennet. iCentrale is een Nederlands programma waarin decentrale overheden samenwerken met particuliere partijen om centrales voor verschillende domeinen te integreren en te innoveren.



Figuur 3.1: ring A10 Amsterdam



Figuur 3.2: Veluwedreef Almere

3.2 De kwaliteit van de voorspellingen

De kwaliteit van de module is bepaald door de voorspelde verkeerstoestand te vergelijken met de werkelijke verkeerstoestand. Om de kwaliteit te bepalen is een evaluatiemodule ontwikkeld. Voor de pilots op de ring A10 Amsterdam en de Veluwedreef Almere worden de uitkomsten gegeven.

De performance-indicatoren

Om de performance te meten is per wegvak de werkelijke gemeten snelheid vergeleken met de gemodelleerde snelheid. De gemeten situatie en de gemodelleerde situatie zijn beide geassocieerd als file of geen file. Zodoende ontstaat vier kwadranten, te weten:

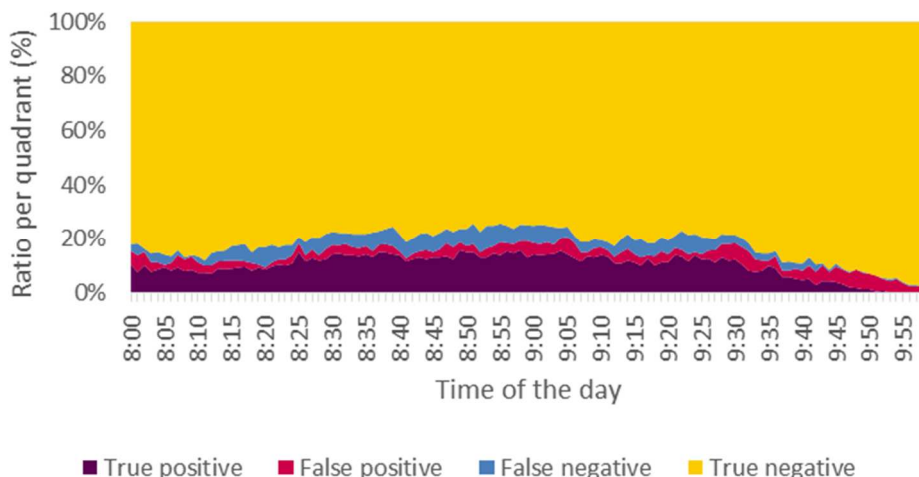
File in zowel werkelijkheid als model (true positive)	Wel file in model maar niet in werkelijkheid (false positive)
File in werkelijkheid maar niet in model (false negative)	Geen file in zowel werkelijkheid als model (true negative)

Voor iedere link in het model is per minuut bepaald in welk van deze kwadranten de vergelijking tussen werkelijkheid en model valt.

Voor het hoofdwegennet is tevens de totale hoeveelheid congestiekilometers per minuut in het netwerk volgens de metingen en volgens het model met elkaar vergeleken.

De kwaliteit op het hoofdwegennet

In figuur 3.4 is de verdeling van de vier kwadranten gedurende een gemiddelde ochtendspits op de ring Amsterdam weergegeven. Het betreft de voorspelling van de actuele situatie op t_0 .

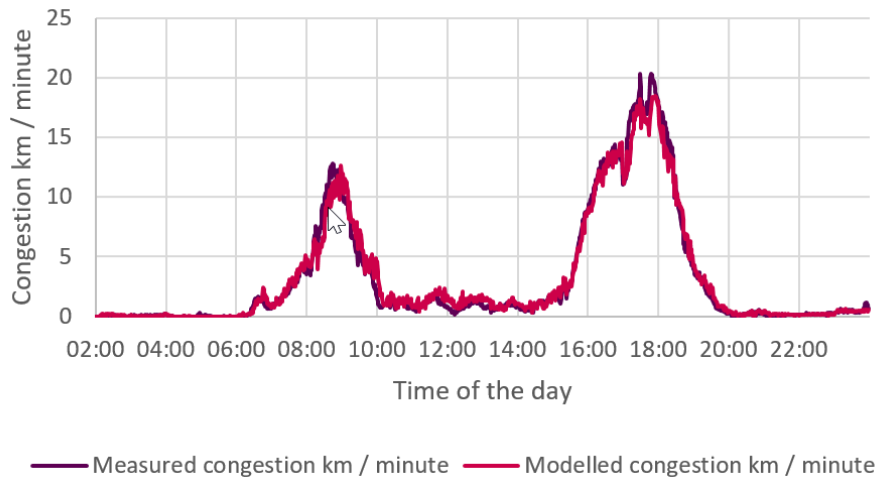


Figuur 3.4: performance ochtendspits ring Amsterdam voor t_0

Figuur 3.4 laat zien dat het netwerk grotendeels in 'free flow' conditie was. Verder zijn het aantal 'false positives' en 'false negatives' redelijk gelijk verdeeld over de tijd, wat betekent dat de nauwkeurigheid niet verschilt van het niveau van de congestie binnen het netwerk. Uit nadere analyse blijkt dat het model in sommige gevallen congestie op enkele segmenten stroomafwaarts van de feitelijke filelocatie voorspelt. Ook blijkt dat in sommige gevallen het model de snelheid van de schokgolf van een wachtrij licht over- of

onderschat. Geaggregeerd blijkt dat de methodiek in meer dan 90% van de gevallen de juiste verkeersstoestand voorspelt. Voor de toepassing binnen pro-actief verkeersmanagement valt dit ruim binnen de marges en mag er best grover worden gescoord.

In figuur 3.5 staan de 6 minuten vooruit voorspelde hoeveelheid congestiekilometers vergeleken met de gemeten omvang.

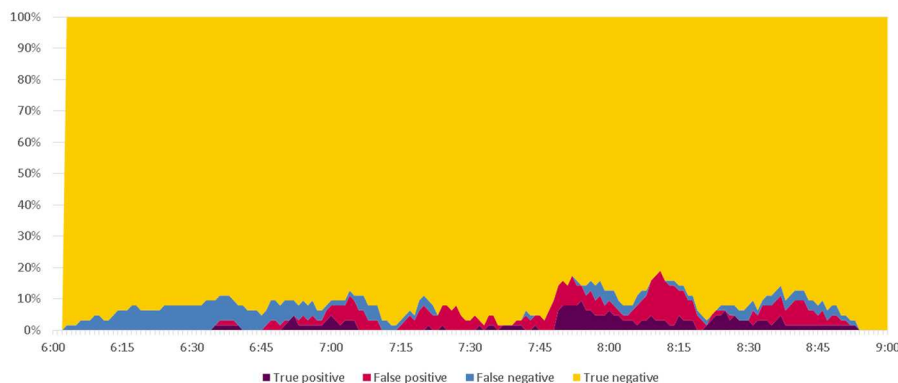


Figuur 3.5: performance congestiekilometers ring Amsterdam voor $t_0 + 6$ minuten

Figuur 3.5 laat zien dat het model in staat is om de fluctuatie van de congestie gedurende de dag te goed voorspellen.

De kwaliteit op het onderliggend wegennet

In figuur 3.6 is de verdeling van de vier kwadranten gedurende een gemiddelde ochtendspits op de Veluwedreef Almere weergegeven. Het betreft de voorspelling van de actuele situatie op t_0 .

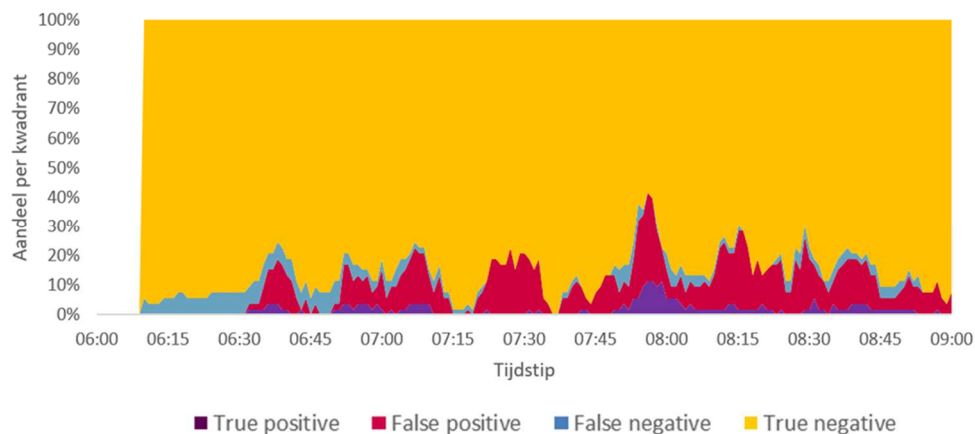


Figuur 3.6: performance ochtendspits Veluwedreef Almere voor t_0

Figuur 3.6 laat zien dat er nauwelijks sprake van congestie is en het model ook geen congestie voorspelt. In het eerste uur zijn er relatief veel 'false negatives', daarna zijn er relatief meer 'false positives'. In totaliteit scoort de methodiek een nauwkeurigheid van 96% waarbij de juiste verkeersstoestand wordt geschat in de huidige situatie. Het verschil

in false positives of false negatives wordt met name veroorzaakt door de dichtheid aan FCD-probes. Deze is op het onderliggend wegennet soms erg dun in onze case. Dat betekent dat het voorkomt dat een lage gemeten snelheid lang in de gemeten data door blijft werken, ook als er in werkelijkheid sneller wordt gereden, maar er eenvoudig geen nieuwe daadwerkelijke meting is. Het model ziet daardoor geen reden, vanwege de actuele intensiteiten die steeds worden gemeten met VLOG-data, en de actuele modelparameters, om een file te verwachten. De verwachting is dat een verbetering in de beschikbare data de performance sterk zal laten verbeteren.

In figuur 3.7 staat de voorspelling voor 10 minuten vooruit.



Figuur 3.7: performance ochtendspits Veluwedreef Almere voor $t_0 + 10$ minuten

Opvallend is dat er beduidend meer 'false positives' optreden. De totale nauwkeurigheid hiervan bedraagt 88% (dat wil zeggen dat in 88% van de gevallen de juiste verkeersstoestand wordt voorspeld). Ook hier gelden de verzachtende omstandigheden die al waren gemeld bij de kwaliteitsanalyse voor t_0 . Aangezien dat ook doorwerkt in de voorspelling. En ook hier heeft de analyse laten zien dat de fout precies zit op een beperkt aantal wegvakjes aan de rand van de file. Meer probes, of continue snelheidsdata (bijvoorbeeld uit lusdetectoren) gaat ook hier zeker de performance sterk verbeteren.

Kwaliteit van de incident detectie

De incident detectie is lastig verifieerbaar. In de eerste plaats moeten zich incidenten in werkelijkheid voordoen. Zo deden zich op de Veluwedreef in Almere tijdens de studie geen incidenten voor. In tweede plaats ontbrak een actuele bron waarin incidenten worden vastgelegd. Van een drietal incidenten die het model op de ring A10 detecteerde konden we achterhalen dat het om werkelijke incidenten ging. De methode lijkt in potentie bruikbaar, maar meer incident-data zijn nodig om de methode verder te tunen.

4. Conclusies en hoe verder

Op basis van analyses naar de performance van de korte-termijnvoorspeller voor een tweetal toepassingen kunnen de volgende conclusies worden getrokken:

- Het model is goed in staat de actuele metingen te reproduceren.
- Het model is goed in staat te komen met een betrouwbare korte-termijnverwachting.

- De kwaliteit van de resultaten is sterk afhankelijk van de kwaliteit van de snelheidsdata. De intensiteiten op het onderliggende wegennet van Almere zijn laag waardoor de kwaliteit van de beschikbare FCD niet altijd voldoende is voor dit type operationele toepassingen waarbij uitspraken worden verwacht op segmenten. Dat wil dus niet zeggen dat deze FCD niet geschikt is om iets te zeggen over de reistijden op trajecten in Almere aangezien hiervoor lagere penetratiegraden reeds voldoen.
- De performance van het systeem wordt nu bekeken over de tijd heen per wegsegment. Met clustering van wegsegmenten in ruimte en tijd (om aan te geven dat het om dezelfde file gaat) wordt de performance ongetwijfeld beter en zelfs in een relatief beperkt bemeeten corridor een goed resultaat wordt behaald.

Naast het doorvoeren van inhoudelijke verbeteringen is de volgende stap om de module als een datadienst aan te bieden voor een verkeersmanagementsysteem. In CHARM zijn hier eerste ervaringen mee opgedaan, waar een koppeling met het verkeersmanagementsysteem Dynac is gemaakt. Naast het leveren van actuele intensiteiten en snelheden en de predictie voor de komende minuten, worden incidenten en onverwachte verkeerstoestanden als triggers aangeboden voor een verkeersmanagementsysteem. Hierdoor kunnen beslissingen om maatregelen in te zetten eerder genomen worden of juist niet worden ingezet. Via de GUI kan de operator inzoomen naar het gewenste deel van het netwerk gaan en met een schuifbalk in de tijd zien hoe de congestie zich naar verwachting ontwikkelt.

Literatuur

[1] L.J.J. Wismans, J. Henckel & W. Janse (2015). Real-time inzicht in verkeersstromen met VRI lusdata. In proceedings CVS conference, November 2015, Antwerpen, Belgium. http://www.cvs-congres.nl/cvspdfdocs_2015/cvs15_002.pdf

[2] Hinsbergen, van, C.P.IJ., J.W.C. van Lint, F.M. Sanders; Short Term Traffic Prediction Models; Advanced Traffic Monitoring; 2007.

[3] zie url <http://www.omnitrans-international.com/nl/download/191implementation-of-a-single-dynamic-traffic-assignment-model-on-mixed-urban-and-highway-transport-networks-including-junction-modelling>.