

Inzichten in mobiliteitsgedrag met AI: een eerste verkenning

Taoufik Bakri
TNO¹

Nico Spijkers
Ministerie van Infrastructuur en Waterstaat²

Fieke Beemster
TNO³

Bachtijar Ashari
TNO⁴

Liselotte Bingen
Ministerie van Infrastructuur en Waterstaat⁵

Themanummer CVS 2022

[De originele bijdrage voor het CVS](#)

¹TNO : taoufik.bakri@tno.nl

²Ministerie van Infrastructuur en Waterstaat: nico.spijkers@minienw.nl

³TNO: fieke.beemster@tno.nl

⁴TNO: bachtijar.ashari@tno.nl

⁵Ministerie van Infrastructuur en Waterstaat: liselotte.bingen@minienw.nl

1. Inleiding

In het huidige tijdperk waarin steeds meer databronnen beschikbaar komen, groeit de complexiteit van de te modelleren systemen. De opgaven op het gebied van infrastructuur, mobiliteit en leefomgeving vragen om nieuwe inzichten die bijdragen aan nieuwe oplossingsrichtingen. Nieuwe mobiliteitsconcepten en -technologieën bieden daarbij kansen om bij te dragen aan de maatschappelijke doelen bereikbaarheid, veiligheid, leefbaarheid en duurzaamheid.. Een van die technologieën betreft Artificial Intelligence (AI) en gerelateerde data science technieken die in het mobiliteitsdomein kunnen worden ingezet om automatisch inzichten af te leiden uit datasets. De grotere beschikbaarheid van hoogfrequente en dynamische data lenen zich daar goed voor om die technieken steeds meer te introduceren en toe te passen ten behoeve van het opdoen van nieuwe type inzichten. Traditionele (keuze)modellen zullen namelijk steeds meer moeite hebben om diverse kenmerken in de data goed mee te nemen in het model. Zowel TNO als het Ministerie van Infrastructuur en Waterstaat willen daarom graag een verbeterd begrip van nieuwe type analyse technieken, in dit geval AI, om tot inzichten te komen ten behoeve van beleidsopgaven. Daarom is een verkenning gestart naar de inzet van AI technieken om in dit specifieke geval te bekijken of modaliteitkeuze optimaler kan worden voorspeld. Met behulp van AI kan namelijk op automatische wijze de datarepresentatie geleerd worden waardoor relevante vrijheidsgraden en kenmerken die potentieel bepalend zijn voor vervoers- en keuzegedrag kunnen worden vastgesteld op basis van de inputdata en niet zozeer op basis van een vooraf voorgesteld (fysisch)model. Dit geeft een groot voordeel ten opzichte van de meer traditionele aanpak omdat het weinig domein voorkennis vereist. De resultaten zijn dan echter niet altijd goed uitlegbaar en soms zelfs in strijd met expertmatige kennis en vereisen daarom ook een verbeterd begrip van de uitlegbaarheid van een AI model. Deze verkenning geeft een kort inkijkje in zowel de toepassing als het verkrijgen van een verbeterd begrip hoe een AI model keuzes maakt waarbij in dit geval is gekeken naar hoe modaliteitskeuze voorspeld kan worden.

2. Methode

Het toepassen van een AI model kent een uitgebreide dataverwerkingsgehalte. De aanpak/methodiek in deze verkenning bestaat uit de volgende stappen:

- **Datapreparatie, verzameling & verrijking**
 - ODiN 2019 data wordt opgeschoond: Rijen met ontbrekende of foutieve data worden verwijderd. Rijen binnen dezelfde zone worden ook verwijderd omdat het niet mogelijk is om de alternatieven hiervoor te genereren met bijbehorende kosten, reistijd etc.
 - ODiN 2019 wordt verrijkt met de reisalternatieven. In de ODiN staan immers slechts de gekozen modaliteit van de reiziger geregistreerd. In deze stap wordt gekeken naar wat de alternatieve modaliteiten waren voor deze reis en de bijbehorende attributen zoals kosten reistijd etc. Deze alternatieven worden dan toegevoegd aan de ODiN
 - Historische KNMI (radar) neerslag data worden verwerkt
 - Datafusie van KNMI neerslag data met de verrijkte ODiN
 - Verrijkte ODiN omzetten naar een formaat geschikt voor het AI model

- **AI aanpak/analyse**
 - AI model trainen en valideren op verrijkte en voorbewerkte ODiN data
 - AI model testen en lijst met relevante features genereren
 - AI model vergelijken met Machine Learning (ML) model Decision tree
- **Impact extra bron**
 - Extra bron bewerken en geschikt maken voor fusie met verrijkte ODiN
 - AI model opnieuw trainen en valideren
 - Impact op relevante features duiden
- **Conclusies en aanbevelingen**

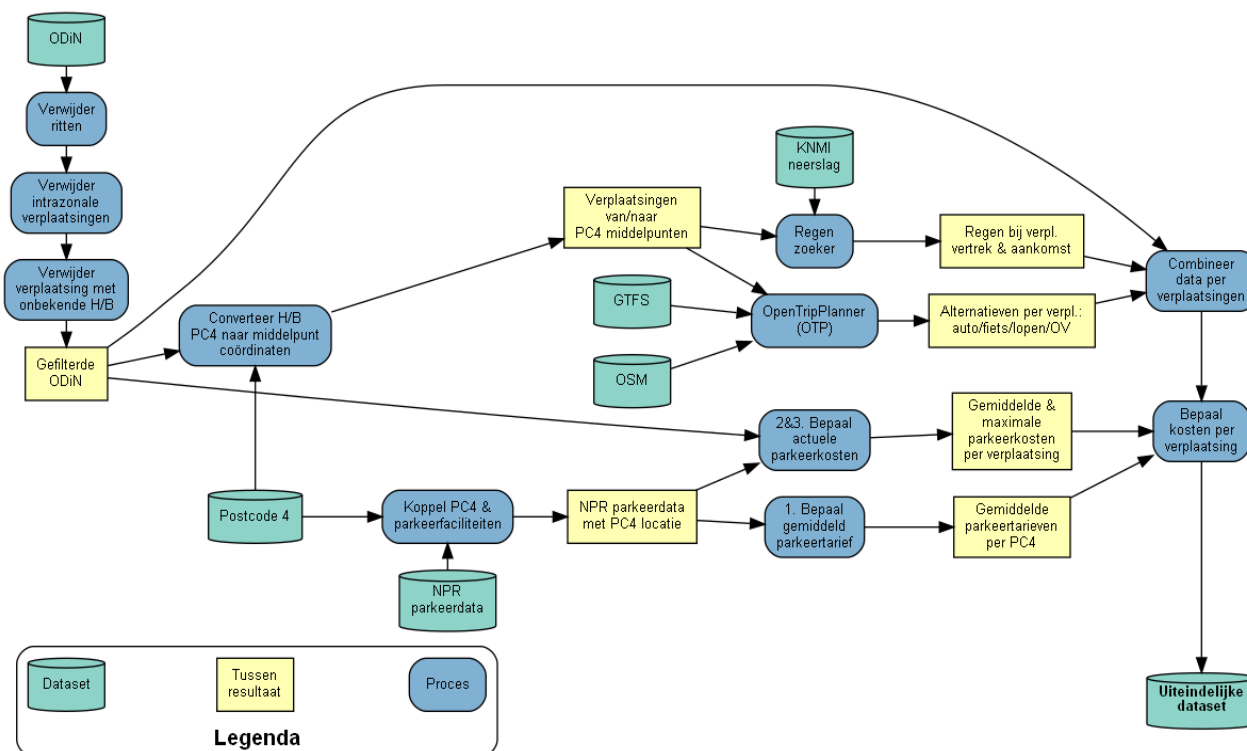
Het werken met een AI model kent een aantal stappen die wij in dit hoofdstuk verder kort zullen toelichten om een beeld te geven wat de benodigde stappen zijn. Eerst wordt ingegaan op de datapreparatie die nodig is zodat deze kan dienen als input voor het model. Hierna wordt een beschrijving gegeven van de methode om de hyperparameters van het model te schatten waarna de topologie van het netwerk wordt vastgelegd. De train-, validatie- en testfases worden vervolgens in detail beschreven. De resultaten van het model worden gepresenteerd in termen van AI kpi's zoals *accuracy, precision, recall en f1-score*⁶. Het AI model wordt ter benchmarking ook vergeleken met een standaard en uitlegbaar *machine learning* algoritme, *decision tree*. Tot slot wordt de '*feature importance*'⁷ besproken. Hierin geeft het AI model de belangrijkste kenmerken die nodig zijn om keuzegedrag te voorspellen en hoe (positief of negatief) een kleine verandering in deze kenmerken de modaliteitenkeuze beïnvloedt (elasticiteiten).

2.1 Dataset voorbereiding en fusie

Figuur 1 toont op hoofdlijnen het proces dat is gevolgd om tot de uiteindelijke dataset te komen. Voor elke verplaatsing en elk alternatief is vervolgens op basis van de afstand en de parkeertarieven op de bestemming een prijs bepaald. Hier worden gemakshalve de tours, ketenreizen en reizen binnen dezelfde zone buiten beschouwing gelaten. Dit resulteert in een dataset die zowel de gemaakte keuze toont uit ODiN, als de bijbehorende parameters van de alternatieven, persoonskenmerken en omgevingsfactoren. Data voorbereiding en fusie wordt veelal, ten onrechte, onderbelicht in wetenschappelijke artikelen. Men gaat er meestal vanuit dat de data al is en bewerkt en voldoet aan de eisen. We geven hier derhalve een inkijkje in de processen die onder de motorkap schuilen om tot de verrijkte dataset te komen die als input zal dienen voor het AI model.

⁶ Precision is een maat voor false positives, recall is een maat voor false negatives en f1-score is het harmonisch gemiddelde van beide maten en geeft een algemene prestatie van het model aan. Accuracy is het percentage correcte voorspellingen van het model

⁷ Hiermee wordt bedoeld: Een score die het belang van de kenmerken voor het AI model weergeeft



Figuur 1: Voorbereiding van de gegevens.

2.2 AI methode

Voor het voorspellen van keuzegedrag wordt in deze fase gebruik gemaakt van een neurale netwerk, een zogenaamd *Feed Forward dense neural network (FFNN)*. De input voor het (FFNN) model bestaat volgende 29 kolommen/ kenmerken uit de verrijkte de ODiN⁸.

Deze kenmerken zijn de meest relevante en voor de hand liggende kenmerken om in eerste instantie mee te nemen in het model. Deze kenmerken nemen grofweg de volgende belangrijke eigenschappen van de reis in acht namelijk: Eigenschappen m.b.t. de modaliteit: reistijd en reiskosten; Eigenschappen m.b.t. het type reis: huis, woon-werk, zakelijk, recreatief/anders en Eigenschappen van de reizigers, de zogenaamd meta data zoals onder meer: Geslacht, inkomen, autobezit, bezit rijbewijs.

De verrijkte ODiN data bestaat verder uit maar liefst 150.000 rijen/verplaatsingen gemaakt door ongeveer 50.000 mensen en is daarmee geschikt om AI-analyses op toe te passen.

De beschouwde modaliteiten In dit project komen overeen met de 'Choice' kolom in de verrijkte ODiN en zijn als volgt: Auto als bestuurder; Auto als passagier; OV (bus, tram, metro of trein); Fiets en Lopen.

⁸ 'sted_o', 'ovstkaart', 'weekday', 'd_hhchildren', 'd_high_educ', 'gender', 'driving_license', 'car_ownership', 'main_car_user', 'hh_highinc20', 'hh_lowinc20', 'pur_home', 'pur_work', 'pur_busn', 'pur_other', 'departure_rain', 'arrival_rain', 't_cycle', 't_transit', 'c_car', 'c_transit', 'pc_car', 't_walk', 't_carp', 't_car', 'sted_d', 'AGE1E', 'AGE2E', 'AGE3E'

3. Resultaten

Om te weten te komen hoe het AI model heeft gepresteerd (lees ook geleerd) op basis van de verrijkte datasets is de methodiek toegepast van trainen, valideren en vervolgens testen. De resultaten die hieronder worden besproken zijn de resultaten op basis van de testset. De eerste set aan resultaten zijn uitkomsten op basis van de dataset ODiN zonder parkeerkosten. Uit tabel 1 is af te leiden dat het model weinig moeite heeft met het voorspellen van vervoerkeuze voor de opties lopen, fietsen en auto als bestuurder. De F1 score is daar ruim voldoende⁹. Voor de opties auto als passagier en OV lijkt het model meer moeite te hebben om te komen tot de juiste voorspelling in verband met een lage recall.

3.1 Resultaten zonder parkeerkosten

Tabel 1: Resultaten FFNN model op de test data.

Modaliteit	Precision	Recall	F1-score	Support ¹⁰
Car	0.764	0.934	0.841	51949
Car passenger	0.905	0.381	0.536	16472
Transit	0.806	0.469	0.593	9234
Cycle	0.742	0.819	0.778	41378
Walk	0.993	0.890	0.939	23389
Accuracy			0.800	142422
Macro average	0.842	0.699	0.737	142422
Weighted average	0.814	0.799	0.787	142422

Valideren met decision tree met een maximale diepte van 5 blijkt niet significant beter te presteren, wat in de regel betekent dat dit Neural Network model goed presteert vergeleken met een standaard machine learning algoritme.

3.2 Resultaten met parkeerkosten

Na het verwerken van de parkeertarieven is de originele ODiN data verrijkt met data over parkeerkosten. Voor elke verplaatsing in de ODiN worden de bijbehorende parkeerkosten voor de auto als bestuurder, indien beschikbaar, toegevoegd.

De scores in Tabel 2 (met parkeerkosten) wijken enigszins af op modaliteiten niveau van de resultaten in Tabel 1 (zonder parkeerkosten). Echter, de overall scores van het model op Accuracy, Marco average en Weighted average wijken globaal nauwelijks af van elkaar. Het toevoegen van de parkeerkosten als extra bron heeft duidelijk geen negatief effect op de overall scores van het model.

⁹ De scores zijn weergegeven tussen 0 en 1, waarbij een score dichterbij de 1 een betere performance laat zien gegeven het leerdoel van het model in ons geval het voorspellen van modaliteitskeuze.

¹⁰ Het totaal aantal waarnemingen

Tabel 2: FFNN model op de testdata met max parkeerkosten variant.

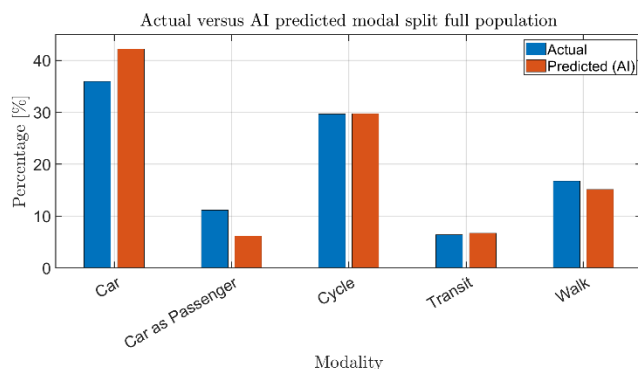
Modaliteit	Precision	Recall	F1-score	Support
Car	0.763	0.895	0.823	49193
Car passenger	0.780	0.432	0.556	15294
Transit	0.603	0.630	0.616	8817
Cycle	0.762	0.764	0.763	40548
Walk	0.983	0.889	0.934	22953
Accuracy			0.790	136805
Macro average	0.778	0.722	0.739	136805
Weighted average	0.791	0.786	0.781	136805

De zogeheten *feature importance*¹¹ laat zien welke kenmerken belangrijk zijn (zwaar wegen) i.r.t. het voorspellen van een vervoersoptie. Hieronder volgt een tabel met en zonder verrijkte parkeerkosten data. Wat hier opvalt is de afwezigheid van het parkeerkostenkenmerk in de top 10. Blijkbaar heeft het algoritme dit kenmerk niet nodig om tot een accurate voorspelling te komen. Wel introduceert deze parkeerkostendatabron een verschuiving bij de top 10 belangrijkste kenmerken. Het gewicht van de reistijd van de auto als bestuurder is dusdanig zwaarder geworden dat dit kenmerk op nummer 1 is komen te staan. Verder zijn de variabele kosten van de auto als bestuurder helemaal uit de top 10 verdwenen. Een mogelijk verklaring kan zijn dat de toegevoegde parkeerkosten correleren met zowel de reistijd van de auto als de variabele kosten van de auto *vc_car* in de data. In dat geval, kan het AI model door de introductie van de parkeerkosten snel inzien dat deze variabelen weinig informatie toevoegen en daardoor niet als belangrijk kenmerk bestempelen. Naast deze typische AI indicatoren laat Figuur 1 zien wat het betekent voor de modal split in de ODin versus het door AI voorspelde model split. Kortheidshalve wordt slechts de modal split met parkeerkosten vertoond. De modal split zonder parkeerkosten toont nagenoeg hetzelfde beeld. De modal split resultaten laten zien dat het Ai model de auto aandeel enigszins overschat en de “auto als passagier” juist onderschat.

Tabel 3: De top 10 belangrijkste kenmerken (met en zonder parkeerkosten) verkregen via Decision Tree algoritme.

Feature importance met parkeerkosten	Feature importance zonder
1. t_car 0.31	1. t_cycle: 0.24
2. t_cycle 0.22	2. vc_car: 0.19
3. t_carp 0.16	3. t_walk: 0.15
4. t_walk 0.14	4. t_carp: 0.14
5. driving_license 0.09	5. t_car: 0.11
6. car_ownership 0.03	6. driving_license: 0.09
7. c_transit 0.01	7. car_ownership: 0.03
8. t_transit 0.007	8. c_transit: 0.02
9. ovstkaart 0.006	9. t_transit: 0.01
10. age_2 0.004	10. age_2: 0.005

¹¹ Feature importance wordt vooral via Decision Tree algoritmen berekend. Bij neurale netwerken is deze mogelijkheid niet eenvoudig. In plaats daarvan worden hiervoor de gradiënten gebruikt om te bepalen hoe belangrijk een kenmerk is voor een voorspelling



Figuur 1: Modal split ODiN versus voorspeld met max parkeerkosten.

4. Handelingsperspectief

De nieuwe inzichten in dit project zijn positief en brachten inzichten in het gemak van AI als methode om snel grote hoeveelheden data te analyseren en effectief de belangrijkste kenmerken die er toe doen te identificeren. Hierdoor kan de AI methode mogelijk dienen als een snelle verkenning om de belangrijkste kenmerken van het te modelleren probleem te identificeren. Een domeinexpert kan in dit geval met behulp van de output van een AI model de nieuwe inzichten en kenmerken meenemen in de modellering van een transparant (fysisch) model om tot een beter model te komen waarbij rekening kan worden gehouden met meer gedetailleerde kenmerken. Tot slot geeft AI in de context van diverse beleidsscenario's de mogelijkheid om via de gradiënten de mogelijke impact van maatregelen snel in te schatten en meerdere "What if scenario's" sneller te verkennen. Een combinatie van beide (traditionele en AI) aanpakken waarbij zowel domeinkennis als AI worden gebruikt biedt dan veel toegevoegde waarde. Hierdoor worden zowel complexiteit als uitlegbaarheid tegelijkertijd geadresseerd. De mens/expert wordt vervolgens ingezet om te beoordelen of opgedragen oplossing/voorspelling nadere verfijning behoeft en of opgedragen oplossing uitlegbaar is en aan domein- en ethische randvoorwaarden voldoet. De zogenaamd "Human in the loop" aanpak. Ook is een aantal nadelen van de methode zichtbaar geworden. Sommige verkregen inzichten waren niet direct uitlegbaar vanuit het menselijk gedrag beredeneerd. Dit is inherent aan de AI methode. Het blijft een uitdaging om kennis over gedrag in een AI model te integreren. Dit kan negatieve gevolgen hebben voor een snelle adoptie van AI in de praktijk. Verder is adequate kennis van dataverzameling, datakwaliteitsbeoordeling, datafusie en pre processing een belangrijk maar helaas onderbelicht aspect voor het gebruik van AI als methode. AI algoritmen leunen namelijk zwaar op de inputdata. Kennis en kunde op het gebied van data engineering is hierdoor een noodzakelijke voorwaarde voor het kunnen laten slagen van het toepassen van een AI model.

Tijdschrift Vervoerswetenschap 59, (1), mei 2023, 1 - 8
 T. Bakri, N. Spijkers, F. Beemster, L. Bingen
 Inzichten in mobiliteitsgedrag met AI: een eerste verkenning

Referenties

- Van Cranenburgh, S., Wang, S., Vij, A., Pereira, F., & Walker, J. (2022). Choice modelling in the age of machine learning - discussion paper. *Journal of Choice Modelling*, 42 doi:10.1016/j.jocm.2021.100340
- Van Cranenburgh, S., Alwosheel, A., 2019. An artificial neural network based approach to investigate travellers' decision rules. *Transport. Res. C Emerg. Technol.* 98, 152-166.
- Lee, D., Derrible, S., Pereira, F.C., 2018. Comparison of Four Types of Artificial Neural Network and a Multinomial Logit Model for Travel Mode Choice Modeling. *Transportation Research Record*, 0361198118796971.
- Wang, S., Mo, B., Hess, S., Zhao, J., 2021. Comparing Hundreds of Machine Learning Classifiers and Discrete Choice Models in Predicting Travel Behavior: an Empirical Benchmark.
- Centraal Bureau voor de Statistiek (CBS). (2019). Kerncijfers per postcode. Centraal Bureau voor de Statistiek. <https://www.cbs.nl/nl-nl/dossier/nederland-regionaal/geografische-data/gegevens-per-postcode>
- Centraal Bureau voor de Statistiek (CBS) & Rijkswaterstaat (RWS-WVL). (2020). Onderzoek Onderweg in Nederland – ODin 2019 [Application/pdf,.sps,.dat,.dta,.sav,.csv]. Centraal Bureau voor de Statistiek (CBS). <https://doi.org/10.17026/DANS-XPV-MWPG>
- KNMI, & Overeem, A. (2019). Precipitation—5 minute precipitation accumulations from climatological gauge-adjusted radar dataset for The Netherlands (1 km, extended mask) in KNMI HDF5 format. KNMI Data Services. <https://dataplatform.knmi.nl/dataset/rad-nl25-rac-mfbs-em-5min-2-0>
- OpenStreetMap contributors. (2021). OpenStreetMap data for The Netherlands. Geofabrik. <http://download.geofabrik.de/europe/netherlands-latest.osm.pbf>
- OpenTripPlanner contributors. (2020). OpenTripPlanner (1.5.0) [Java]. Software Freedom Conservancy. <http://www.opentripplanner.org/>
- OV API. (2021). GTFS Nederland. <http://gtfs.ovapi.nl/nl/archive/NL-20210716.gtfs.zip>
- RDW. (2019). Open Data Parkeren: TARIEFDEEL | Open Data | RDW. <https://opendata.rdw.nl/Parkeren/Open-Data-Parkeren-TARIEFDEEL/534e-5vdg>