

Rapportage

Simulatie snelladergebruik

Inleiding

De gemeente Amsterdam streeft naar een uitstootvrije taxibranche in 2025. Dit is de voornaamste doelstelling van het convenant 'schone taxi's voor Amsterdam', dat in 2016 ondertekend werd door de gemeente Amsterdam en alle Toegelaten Taxi Organisaties (hierna: TTO's). In het convenant staan de maatregelen genoemd hoe men tot deze doelstelling kan komen (Gemeente Amsterdam, 2016). Voor de TTO's is het convenant duidelijk; het wagenpark van de organisaties moet vanaf 2025 schoon zijn. Tot 1 januari 2021 betekent schoon: uitstootvrij, plug-in hybride (met CO₂ uitstoot lager dan 50 g/km) en groengas voertuigen. Vanaf 2021 staat schoon enkel voor volledig uitstootvrij.

Aanvullend op het convenant heeft de gemeente Amsterdam in mei 2019 het 'Actieplan Schone Lucht' gepubliceerd. In dit plan staan de doelstellingen van de gemeente om het vervoer in Amsterdam te verschonen. Volgens dit plan moeten naast de TTO's ook alle andere taxiorganisaties in Amsterdam uitstootvrij zijn in 2025 (Gemeente Amsterdam, 2019).

Het convenant en het actieplan betekenen voor de gemeente dat zij zorg moeten dragen voor een toereikend (snel)laadnetwerk in de openbare ruimte. Met name de snelladers hebben grote prioriteit, een taxichauffeur verdient namelijk geld per rit. Lange laadtijden kunnen ten koste gaan van potentiële ritten en zijn daarom ongewenst. Daarnaast geven taxichauffeurs aan dat zij eerder geneigd zijn over te stappen naar een elektrische auto als er meer snelladers beschikbaar zijn (Tamis & Zeiske, 2017).

In dit rapport wordt het SEVA model (Simulation of Electric Vehicle Activity) besproken. Dit data gedreven simulatiemodel is in staat om betrouwbare voorspellingen te doen over de toekomstige laadbehoefte. Het model is eerder succesvol gebleken in het simuleren van laadgedrag bij elektrische voertuigen op reguliere publieke laadpunten (Vermeulen I. , 2017) (Wolbertus, van den Hoed, Kroesen, & Chorus, 2019). Door dit model aan te passen is het ook mogelijk om het laadgedrag bij snelladers te simuleren. Hierdoor is het ook mogelijk om een prognose te maken van de snellaadbehoefte die voortkomt uit de elektrificatie van de taxibranche. De aanpassingen op het model en de resultaten ervan worden in dit rapport beschreven.

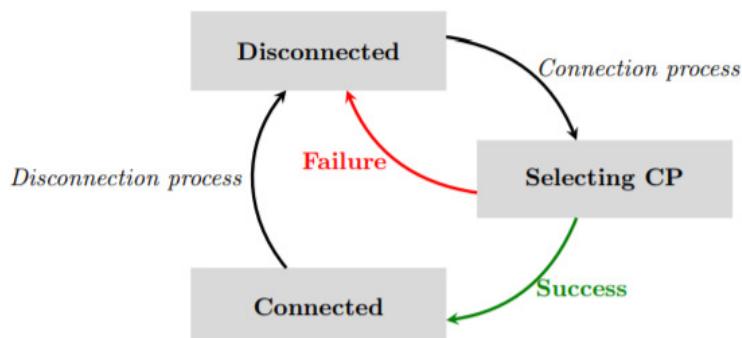
Doelstelling

Een prognose van de toekomstige snellaadbehoefte in Amsterdam.

Algemene werking van het SEVA model

In dit stuk wordt de werking van het SEVA model bondig beschreven. Zoals met alle agent-based modellen bestaat het SEVA model uit agents en een environment. De agents zijn de bestuurders van elektrische taxi's en de environment is de verzameling van laadpunten (Wolbertus, van den Hoed, Kroesen, & Chorus, 2019) (Vermeulen I. , 2017). De agents gaan een interactie aan met hun omgeving (environment) op basis van hun laadgedrag en laadbehoefte. Daartoe heeft elke agent drie eigen datasets die het laadgedrag van de agent definiëren. Deze datasets zijn ontwikkeld op basis van de gegevens uit de CHIEF-database. Ten eerste bestaat de dataset met startdistributies uit momenten waarop de bestuurder een laadsessie begonnen is, met de daarbij behorende duur van de laadsessie en de kans daarop. Vervolgens is er een dataset met gegevens over energieafname (kWh) per laadsessie en startmoment. Een bestuurder die om 13:00 uur vijf keer 20kWh heeft geladen en één keer 5kWh heeft op dat tijdstip een grotere kans om 20kWh te laden dan 5kWh. Tot slot is er een dataset die bepaalt wanneer de eerstvolgende laadsessie van de agent plaatsvindt. De tijden zijn afgeleid uit het verschil in tijd tussen twee elkaar opvolgende laadsessies.

De simulatie verloopt over een vooraf ingestelde tijdsperiode en in stappen van tien minuten. Het proces dat de agents gedurende deze tijdsperiode doorlopen is weergegeven in Figuur 1. Per tien minuten wordt bepaald welke agents moeten laden en welke agents klaar zijn met laden. De communicatie tussen de agents en de laadpalen (environment) verloopt via de sockets van de laadpaal, deze kunnen beschikbaar of bezet zijn. Elke agent die moet laden gaat naar de meest dichtstbijzijnde laadlocatie. De beginlocatie van de agents hangt af van een verdeling die is gebaseerd op 'drop-off' gegevens van Uber. Zo worden de agents over wijken verdeeld naar waarschijnlijkheid. Als er op de locatie een laadpaal beschikbaar is dan zal de agent direct starten met laden. In het geval dat er op deze locatie geen laadpunt beschikbaar is zal de agent naar een andere locatie gaan, dit proces herhaalt zich tot hij kan laden. De laadpoging wordt als *failed* bestempeld als de agent geen beschikbare laadpaal heeft kunnen vinden.



Figuur 1: Een visuele weergave van het proces dat de agents doorlopen.

Bron: (Vermeulen I. , 2017)

Het resultaat van dit simulatieproces is een dataset met gesimuleerde laadsessies, vergelijkbaar met de dataset van de CHIEF-database. Per laadsessie wordt onder andere het tijdstip, het aantal kWh, de connectietijd en de locatie weergegeven. De validiteit van de gesimuleerde data is bepaald door deze te vergelijken met de feitelijke laadsessies.

Specifieke werking van de snellader module

Tijdlijn

De oorspronkelijke tijdlijn van het simulatiemodel verloopt in stappen van een half uur. Omdat laadsessies bij standaard laadpalen doorgaans langer dan een halfuur duren is dit een geschikt interval. Snellaadsessies zijn echter korter en duren gemiddeld zo'n 22 minuten. Ter optimalisatie van het model is daarom gekozen voor een tijdlijn met een interval van tien minuten. De duur van elke laadsessie wordt daarmee op tien minuten afgerond in plaats van een half uur. De simulatie van laadsessies loopt over een periode van 1 november 2018 tot 1 januari 2025.

Agents

De agents zijn de kern van het simulatiemodel. Ze vertegenwoordigen taxi gebruikers in Amsterdam. Het gedrag van elke agent is ontwikkeld op basis van werkelijke laaddata. Deze laaddata is afkomstig uit de CHIEF-database. De laaddata die is gebruikt voor het maken van de laadregels die agents gebruiken bestaat uit snellaadsessies die hebben plaatsgevonden tussen 1 januari 2016 en 30 juni 2018 in Amsterdam. De RFID van de laadpas is gebruikt als ID voor de agent. Uit eerder onderzoek is gebleken dat de Amsterdamse snelladers voornamelijk door taxi's worden gebruikt. Omdat deze groep regelmatig gebruik maakt van snelladers en andere gebruikers slechts sporadisch, zijn de veelvoorkomende gebruikers als taxi's geïdentificeerd. Daartoe zijn ten eerste alle RFID's van deelplatformen (e.g. Car2GO) uit de data gefilterd. Daarnaast zijn de RFID's met minder dan 25 snellaadsessies (over de gegeven periode van 2,5 jaar) uit de data gefilterd. Uit eerder onderzoek bleek ook dat taxichauffeurs regelmatig van laadpas wisselen. Om te voorkomen dat gebruikers dubbel gemodelleerd worden is er gefilterd op de meest recente RFID's (actief tussen 1 november 2018 en 1 juli 2019). RFID's met 25 of meer snellaadsessies worden beschouwd als taxi en zijn opgenomen als agent.

Laadprofiel

Elke agent beschikt over een laadprofiel dat is ontleed uit de laaddata. Het laadprofiel bestaat uit verdelingen van (a) de starttijd, (b) de hoeveelheid kWh geladen energie, (c) disconnectietijd (oftwel de tijd tussen twee sessies). Deze drie gedragsdatasets bevatten alleen gegevens van snellaadsessies. Laadsessies bij standaard laadpalen worden buiten beschouwing gelaten omdat bij standaard laadpalen ander laadgedrag wordt vertoond. Voor elke agent zijn alle waargenomen start- en disconnectietijden verzameld en ondergebracht per tijdseenheid (afgerond op tien minuten). De kans dat een bepaalde start- of disconnectietijd wordt gekozen hangt af van het aantal keren dat die start- of disconnectietijd in werkelijkheid is voorgekomen op dat tijdstip. Dezelfde methode wordt gebruikt voor de te laden hoeveelheid kWh. Het verschil is echter dat er geen verband is tussen het tijdstip en het aantal kWh (Wolbertus, van den Hoed, Kroesen, & Chorus, 2019).

In tabellen 1 tot en met 3 zijn delen van het laadprofiel te zien van een agent met de ID 2260. De tijdskolommen (2 en 3) in Tabel 1 en Tabel 2 zijn in uren. Een laadtijd van bijvoorbeeld 0.1667 uur is daarom $0.1667 * 60 = 10$ minuten. Als een laadsessie om tien over vier begonnen is dan is de Starttijd 4.1667.

Tabel 1: Voorbeeld van een laadprofiel (starttijd)

ID	Starttijd	Laadtijd	n	Kans
2260	4.0000	0.1667	3	0.2307
2260	4.0000	0.3333	3	0.2307
2260	4.0000	0.5000	4	0.3076
2260	4.0000	0.6667	3	0.2307
2260	4.1667	0.1667	3	0.3750
2260	4.1667	0.3333	2	0.2500
2260	4.1667	0.1667	1	0.1250

2260	4.1667	0.1667	1	0.1250
2260	4.1667	0.1667	1	0.1250

Tabel 2: Voorbeeld van een laadprofiel (disconnectietijd)

ID	Disconnectietijd	Tijd tot volgende sessie	n	Kans
2260	5.0000	0.5000	1	0.1250
2260	5.0000	0.6667	1	0.1250
2260	5.0000	0.8333	1	0.1250
2260	5.0000	1.3333	1	0.1250
2260	5.0000	18.500	1	0.1250
2260	5.0000	19.000	1	0.1250
2260	5.0000	20.000	1	0.1250

Tabel 3: Voorbeeld van een laadprofiel (hoeveelheid kWh)

ID	Starttijd	kWh	n	Kans
2260	23.333	3	5	0.3125
2260	23.333	4	3	0.1875
2260	23.333	5	1	0.0625
2260	23.333	6	2	0.1250
2260	23.333	7	2	0.1250
2260	23.333	9	2	0.1250
2260	23.333	14	1	0.0625

Laadpaal selectieproces

Het laadpaal selectieproces zorgt ervoor dat een agent een laadpaal vindt waarmee hij kan verbinden. Het proces wordt in gang gezet voor alle agents die op tijdstip x moeten laden. In het originele SEVA model wordt een laadpaal geselecteerd op basis van gewoonte, oftewel de meest bezochte laadpalen op dat tijdstip door de agent. Daarentegen wordt een snellader in werkelijkheid gekozen op basis van de af te leggen afstand. Om het snellaadgedrag zo realistisch mogelijk te kunnen simuleren is daartoe het selectieproces aangepast.

Ten eerste krijgt elke agent per uur een locatie aangewezen waar hij naar waarschijnlijkheid is. De agents die moeten laden kiezen vervolgens de laadpaal die het dichtst bij hen in de buurt is. Om dit proces te ontwikkelen is gebruik gemaakt van publieke Uber data uit Amsterdam (Uber Movement, 2019). Op basis van deze data is een dataset gemaakt van het aantal 'drop-offs' per wijk en per uur. Deze dataset (Tabel 4) is vervolgens gebruikt om de locaties van de agents te bepalen op een bepaald tijdstip.

Tabel 4: Voorbeeld van de kansverdeling voor wijken

Wijk_ID	Tijd (uur)	Kans	Wijknaam
131	9	0.00177	Wijk 14 Rosmolenwijk
132	9	0.01166	Sloter-/Riekerpolder
133	9	0.00247	Wijk 15 Kogerveldwijk
134	9	0.00725	Slotervaart Zuid
136	9	0.01027	Buitenveldert-West
137	9	0.00486	Wijk 21 Oude Haven

Vervolgens is met behulp van publieke gebiedsdata van de overheid het geografische middelpunt van elke Amsterdams wijk berekend (Nationaal Dataportaal, 2019). Dit middelpunt is als uitgangspunt genomen voor de locatie van de agents. De agents die moeten laden gaan vervolgens vanuit dit punt naar de dichtstbijzijnde snelladerlocatie. Hiervoor is de afstand berekend van de kortste route (Tabel

5). Als hier een vrij laadpunt is dan wordt er verbonden. Mochten de laadpalen bezet zijn dan gaat de agent naar de volgende snelladerlocatie, die het meest in de buurt is (Tabel 6). Dit proces herhaalt zich totdat hij verbonden is of tot er geen locatie meer over is.

Tabel 5: Voorbeeld van de rijdafstand tabel (van wijk naar laadlocatie)

Wijk_ID (van)	Locatie_ID (naar)	Rijafstand (meters)
28	5731	2362
29	6143	2145
30	4836	2990
31	5731	2921
32	1904	3828
33	1904	1510
34	7868	3203

Tabel 6: Voorbeeld van de rijdafstand tabel (van laadlocatie naar laadlocatie)

Locatie_ID (van)	Locatie_ID (naar)	Rijafstand (meters)
4835	7867	1595
4836	6143	2757
5731	7868	4893
5732	2008	817
6143	7867	1597
7867	6143	1656
7868	5731	4083

Tabellen 5 en 6 zijn voorbeelden van tabellen die in het model gebruikt worden. Deze tabellen bevatten de afstanden tussen de wijken en laadlocaties (Tabel 5) en de afstanden tussen de laadlocaties onderling (Tabel 6). Een agent zal altijd de kortste afstand kiezen.

Gedurende de simulatie worden laadlocaties aan het netwerk toegevoegd. Dit heeft als gevolg dat de er een nieuwe kortste afstand kan ontstaan, zowel voor de afstand tussen wijk en laadlocatie (Tabel 5) als voor afstanden tussen laadlocaties onderling (Tabel 6). De afstanden worden daarom opnieuw berekend na het toevoegen van een nieuwe laadlocatie.

Niet frequente bezoekers

Frequente gebruikers zijn gemodelleerd als agents. Daarnaast zijn er echter ook regelmatig laadsessies die worden uitgevoerd door EV-rijders die minder vaak snelladen (niet frequente gebruikers). De laadsessies die deze niet frequente gebruikers uitvoeren worden gesimuleerd door per tijdstap een aantal niet frequente gebruikers toe te voegen. Het aantal niet frequente sessies groeit in gelijke verhouding mee met het totaal aantal agents. Het proces voor niet frequente gebruikers is vergelijkbaar met dat van agents. Het verschil is echter dat de ID's van niet frequente gebruikers niet gebaseerd zijn op RFID's, maar worden deze als 'nonfreq' gelabeld. Daarnaast wordt er voor de niet frequente gebruikers geen nieuwe connectietijd berekend en verdwijnen ze na het ontkoppelen uit het systeem. In plaats daarvan wordt er dus per tijdstap een vaste percentage niet frequente gebruikers toegevoegd.

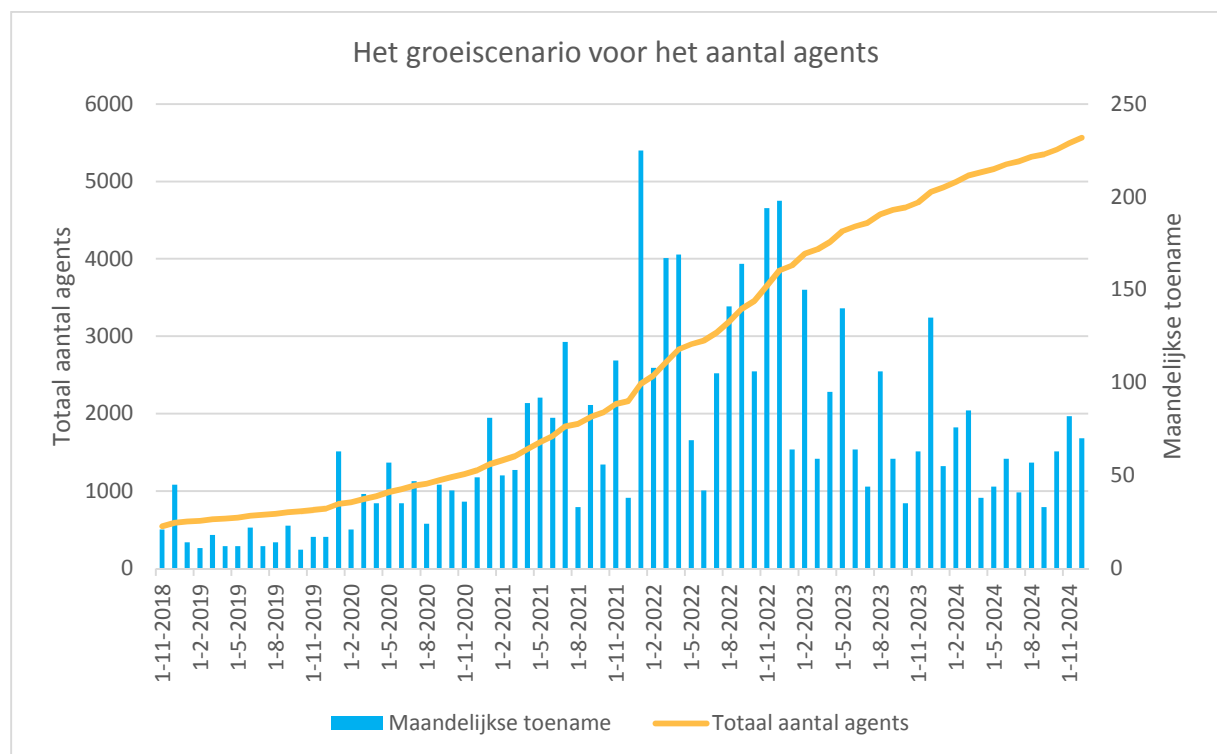
Groei

Om een prognose te maken van het aantal laadsessies is het belangrijk om de groei van het aantal agents te modelleren. Er wordt vanuit gegaan dat voor 2025 alle taxi's elektrisch zijn. Dit is de deadline voor uitstootvrij taxivervoer, volgens het convenant en het actieplan schone lucht (Gemeente

Amsterdam, 2016) (Gemeente Amsterdam, 2019). Daarmee zullen er naar verwachting tussen de 5000 en 6000 elektrische taxi's in Amsterdam zijn, begin 2025.

Het aantal geregistreerde elektrische taxi's aan het begin van november 2018 (start simulatie) is 838 (Taxi monitor, 2019). Van dit aantal maken naar verwachting 590 taxi's (regelmatig) gebruik van de publieke snelladers. Het overige deel bestaat uit Tesla's en elektrische auto's die niet vaak gebruik maken van het publieke netwerk. De overige taxi's maken bijvoorbeeld vaker gebruik van andere snellaad faciliteiten zoals Tesla superchargers of door de TTO zelf geïnstalleerde snelladers.

Er wordt verwacht dat het aantal taxi's met name zal toenemen aan het eind van 2021 en gedurende 2022/2023 zoals overlegd met de gemeente Amsterdam. Tijdens de simulatie neemt het aantal agents toe van 524 in november 2018 tot 5566 in januari 2025. Daarbij neemt het aantal agents ook sterker toe over de periode eind 2021 – 2023. Het groeimodel is weergegeven in Figuur 2.



Figuur 2: Het groeiscenario dat is gebruikt tijdens de simulatie

Environment

De environment is de ruimte waarin agents bewegen. De environment in dit model bestaat uit publieke snellaadlocaties in Amsterdam en de daar aanwezige laadpalen. Deze locaties zijn gemodelleerd in een ruimtelijke context en hebben elk hun eigen lengte- breedtegraad (Wolbertus, van den Hoed, Kroesen, & Chorus, 2019). Ook hebben de locaties een eigen hoeveelheid laadpalen.

Uitbreiding van het netwerk

Omdat de gemeente Amsterdam de komende jaren het snellaadnetwerk zal uitbreiden is dit gemodelleerd. De uitbreiding gebeurt op twee manieren. Ten eerste kan er een nieuwe locatie bijkomen. De locatie wordt op een vooraf bepaalde datum toegevoegd aan de beschikbare locaties. Ten tweede kan het aantal snellaadpalen op een locatie worden uitgebreid. Zo gaat de locatie Pauwenpad op 1 oktober 2019 van één naar twee laadpalen. Het overzicht met uitbreidingen is te zien in Tabel 7 en Tabel 8.

Tabel 7: Overzicht van locatie uitbreidingen op het snellaadnetwerk

Locatie_ID	Adres	District	Latitude	Longitude	Datum toevoegen
1904	Tijnmuiden 53	Westpoort	52.39169	4.77906	2019-04-01
2002	Keienbergweg	Zuidoost	52.30712	4.93408	2020-02-01
2004	Noord (P+R)	Noord	52.40477	4.93407	2020-04-01
2008	Anthony Fokkerweg	Zuid	52.34528	4.84605	2020-08-01

Tabel 8: Overzicht van de capaciteitsuitbreidingen per locatie

Locatie_ID	Adres	Nieuw totaal aantal laadpalen	Datum toevoegen
4835	Europaboulevard 10	4	2019-05-01
5731	Stationsplein 51	3	2019-07-15
4836	Pauwenpad 1	2	2019-10-01
6143	Hobbemakade 121	3	2019-09-15
4835	Europaboulevard 10	10	2019-12-01

Simulaties


Aan de hand van het SEVA model zijn twee simulaties uitgevoerd. Bij beide simulaties neemt het aantal agents toe zoals in het eerder beschreven groeiscenario. De eerste simulatie gaat uit van alle uitbreidingen van het snellaadnetwerk, zoals weergegeven in Tabel 7 en Tabel 8. Het doel van dit experiment is om te zien bij hoeveel laadsessies de nieuwe infrastructuur eenzelfde bezettingsgraad heeft als in de periode oktober 2018 tot februari 2019, dit was tot nu toe de drukste periode in Amsterdam. Op de tien drukste dagen in deze periode waren er 353 tot 399 laadsessies per dag. Als we dit vergelijken met de simulatie, die over deze periode uitgaat van topdrukke, genereert het model over dezelfde periode gemiddeld 10 tot 18 mislukte laadsessies per dag en 377 tot 398 succesvolle laadsessies. Het model komt daarmee dus goed overeen met de drukste dagen op het netwerk.

Met de tweede simulatie wordt onderzocht wanneer het huidige snellaadnetwerk aan zijn limiet raakt. Hierin worden dus geen nieuwe locaties toegevoegd maar wordt er wel rekening gehouden met de uitbreiding van bestaande locaties (Tabel 8). De locatie Tijnmuiden wordt in april 2019 wél toegevoegd, omdat dit in werkelijkheid ook al is gebeurd.

Resultaten

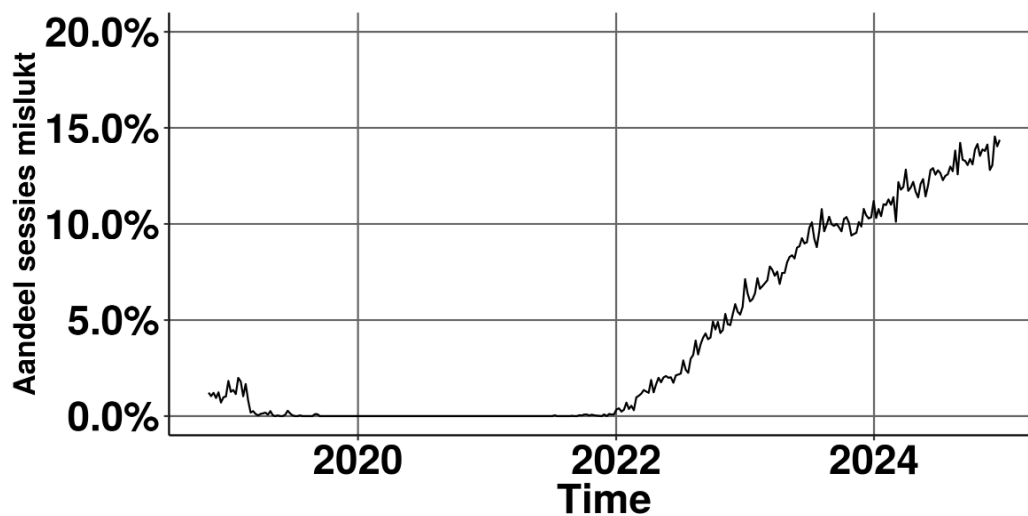
Simulatie 1

De resultaten van de eerste simulatie zijn te zien in Figuur 3. Het toevoegen van agents resulteert in een groeiend aantal laadsessies. De verwachting is dat in 2025 het aantal gebruikers en het aantal sessies bijna tien keer zo groot is.



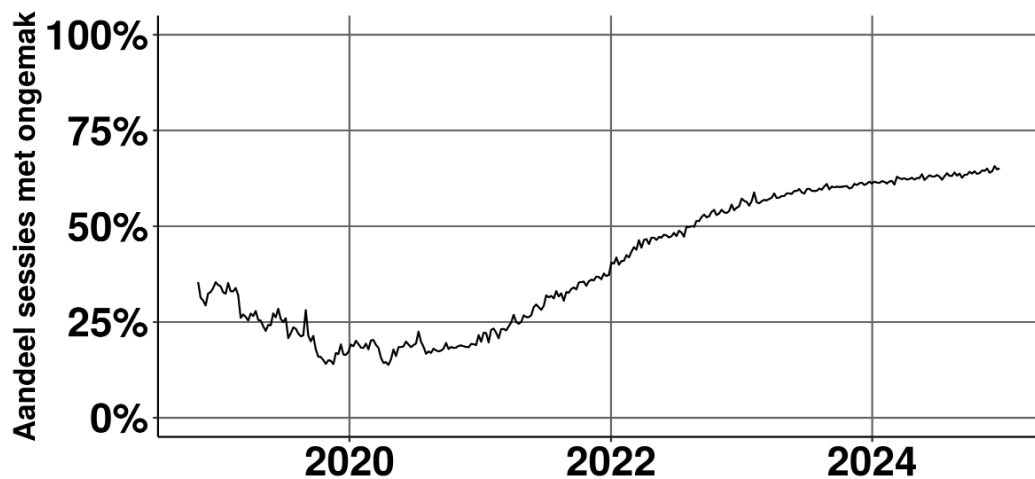
Figuur 3 Toename van gebruikers en sessies op snellaadnetwerk

Agents die niet kunnen laden als gevolg van een volledig bezet netwerk resulteren in zogenaamde mislukte sessies. Het huidige snellaadnetwerk, inclusief de geplande uitbreidingen (Tabel 7 en Tabel 8), blijkt met de beoogde groei voldoende capaciteit te hebben tot het begin van 2022. Vanaf 2022 neemt het aandeel mislukte laadsessies snel toe. Het netwerk begint vanaf dat moment vol te raken. Dit is ongeveer bij een toename van 300%, een verviervoudiging van het aantal elektrische taxi's momenteel.



Figuur 4: Simulatie resultaten experiment 1

Aangezien de simulatie er vanuit gaat dat taxi's eerst alle snelladers langsgaan voordat de sessie mislukt is het goed om te kijken of er al eerder discomfort optreedt door wachtrijden bij snelladers. Dit wordt gemonitord door te kijken bij welk aandeel van de sessies de taxi chauffeur heeft moeten omrijden om uiteindelijk te kunnen laden. De resultaten van deze analyse zijn weergegeven in figuur 4. Hier is zichtbaar dat ondanks dat in de periode tot 2022 er nauwelijks mislukte sessies er wel substantieel aandeel is van taxi chauffeurs die moeten omrijden. Deels is dit omrijdgedrag te verklaren door de locaties van snelladers ten opzichte van de drop-off punten die uit de Uber data zijn gebruikt. Als voorbeeld: de locatie Anthony Fokkerweg ligt nooit als eerste snellaadpunt ten opzichte van een drop-off punt, taxi chauffeurs zullen in het model dus altijd langs snellaadlocaties gaan met minder aansluitingen. In de praktijk zullen chauffeurs vanzelf eerst naar locaties gaan rijden die vaker beschikbaar zijn.

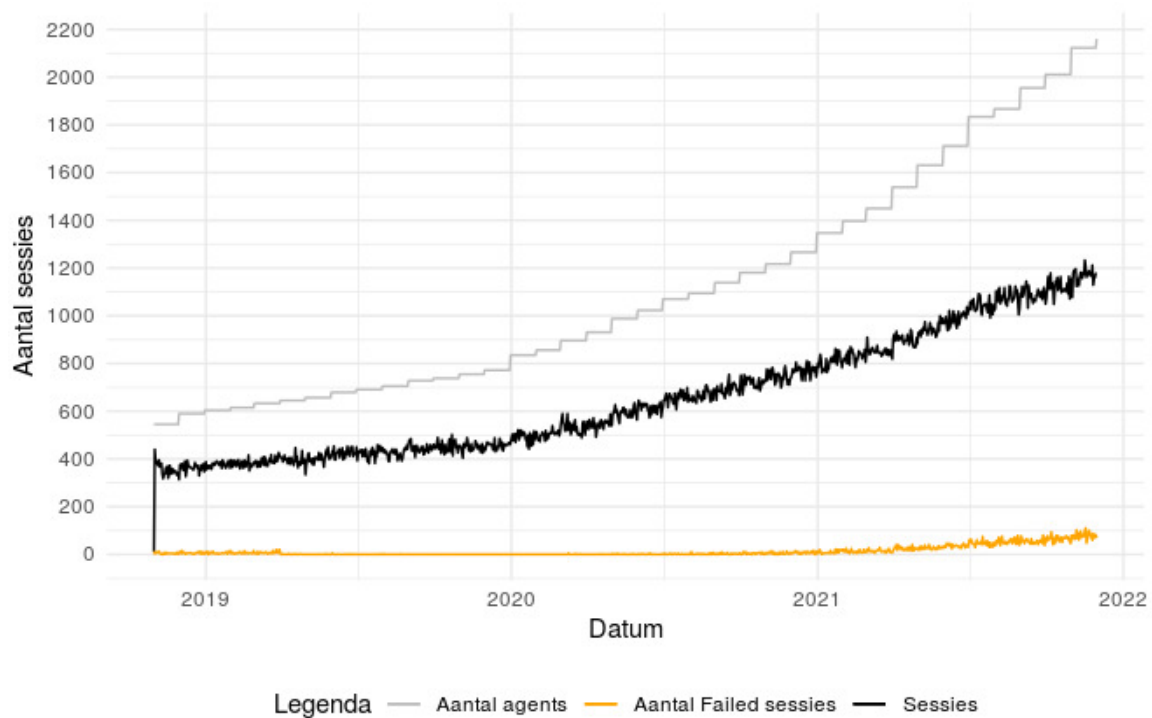


Figuur 5 Aandeel sessies waarbij de gebruiker moet omrijden om beschikbare laadpaal te vinden

Het aandeel sessies met ongemak is nuttig in het herkennen van kritieke punten dat het aantal omrijdbewegingen al in 2021 begint toe te nemen, een jaar eerder dan het aantal mislukte sessies. Dit geeft aan dat vanaf 2021 er dus al sprake is van toenemende druk op het netwerk en dus mogelijke klachten van taxi chauffeurs over bezette laadpalen.

Simulatie 2

De resultaten van de tweede simulatie zijn te zien in Figuur 4. In deze simulatie zijn geen nieuwe laadpalen neergezet (m.u.v. Tijnmuiden). Het eerste dat opvalt is dat het toevoegen van die nieuwe locatie Tijnmuiden resulteert in een daling van het aantal mislukte laadsessies. Het gemiddelde aantal mislukte laadsessies vóór het toevoegen van Tijnmuiden was meer dan 5,5 per dag. Na het toevoegen is dit aantal nagenoeg 0. In juli 2020 komt het gemiddelde aantal mislukte laadsessies weer boven 1 per dag. In september zijn dat er 2,5 en in december 8. Aan het begin van Q4 2020 begint het netwerk dus weer vol te lopen. Op dat moment zijn er gemiddeld 700 laadsessies per dag. Het aantal agents is tot dat moment 2,2 keer zo groot geworden (van 524 in november 2018 tot 1150 in oktober 2020).



Figuur 6: Simulatie resultaten experiment 2

Conclusie

- Met alle geplande uitbreidingen (Tabel 7 en Tabel 8) van het Amsterdamse snellaadnetwerk zal bij een verviervoudiging van het aantal dagelijkse laadsessies het netwerk een zelfde service kunnen bieden als in de drukke periode oktober 2018 tot februari 2019. Uitgaande van het beschreven groeiscenario gebeurt dit volgens het model eind 2021.
- In een eerdere fase zullen chauffeurs wel al ondervinden dat het netwerk voller raakt. Ze zullen dan vaker naar een andere locatie moeten rijden of wachten voor een beschikbare snellader. Dit is zichtbaar in het aandeel van taxi's met ongemak. Dit gebeurt wanneer het aantal taxi's is verdrievoudigd (met het gegeven groeiscenario begin 2021)
- Zonder de nieuwe locaties maar met uitbreiding van de huidige locaties (Tabel 8) zal het netwerk begin Q4 dezelfde bezettingsgraad hebben als in de winter 2018/2019. Het aantal laadsessies per dag is dan 75% toegenomen en het aantal agents 2,2 keer zo groot.
- Beperkingen van het onderzoek
 - Er is slechts in beperkte mate zekerheid dat de geobserveerde gebruikers ook daadwerkelijk taxi gebruikers zijn
 - Het simulatiemodel geeft aan dat nu al tijdens drukke periodes er sessies mislukken. Dit is echter niet te valideren.
 - Er is nog weinig bekend over TTO's of andere centrales met eigen laadfaciliteiten
 - Er is nog weinig bekend over de invloed van andere snelladers buiten de stadsgrenzen
 - Goede informatievoorziening over beschikbaarheid van snelladers kan invloed hebben op laadkeuzes
 - Er is nog geen rekening gehouden met de toenemend snelheden bij het laden. Bij een grote capaciteit kan de doorloop mogelijk sneller zijn.

Referenties

- Azadfar, E., Sreeram, V., & Harries, D. (2015). The investigation of the major factors influencing plug-in electric vehicle driving patterns and charging behaviour. *Renewable and Sustainable Energy Reviews*, 1065-1076.
- Franke, T., & Krems, J. (2013). Understanding charging behaviour of electric vehicle users. *Transportation Research Part F*, 75-89.
- Gemeente Amsterdam. (2016, Februari). *Convenant Schone taxi's voor Amsterdam*. Amsterdam, Noord-Holland, Nederland.
- Gemeente Amsterdam. (2019). *Actieplan Schone Lucht*. Amsterdam: Gemeente Amsterdam.
- Helmus, J. (2015). *Promotievoorstel*.
- Macal, C., & North, M. (2010). Tutorial on agent-based modelling and simulation. *Journal of Simulation*, 151-162.
- Nationaal Dataportaal. (2019, mei). *Gebiedsindeling Amsterdam*. Opgehaald van Overheid.nl: <https://data.overheid.nl/dataset/mea3qdtvln9ca>
- Spoelstra, J. (2014). *Charging behaviour of Dutch EV drivers*.
- Sweda, T., & Klabjan, D. (2011). An Agent-Based Decision Support System for Electric Vehicle Charging Infrastructure Deployment. *IEEE Vehicle Power and Propulsion Conference*, pp. 1-5.
- Tamis, M., & Zeiske, N. (2017). *Resultaten taxi survey september 2017*. Amsterdam.
- Uber Movement. (2019, Mei). *Movement*. Opgehaald van Uber Movement: [https://movement.uber.com/explore/amsterdam/travel-times/query?lang=nl-NL&si=30&ti=&ag=wijk&dt\[tpb\]=ALL_DAY&dt\[wd;\]=1,2,3,4,5,6,7&dt\[dr\]\[sd\]=2018-01-01&dt\[dr\]\[ed\]=2018-01-31&cd=&sa;=&sdn=](https://movement.uber.com/explore/amsterdam/travel-times/query?lang=nl-NL&si=30&ti=&ag=wijk&dt[tpb]=ALL_DAY&dt[wd;]=1,2,3,4,5,6,7&dt[dr][sd]=2018-01-01&dt[dr][ed]=2018-01-31&cd=&sa;=&sdn=)
- Vermeulen, I. (2017). *An Agent-Based Model for the Simulation of Charging Behaviour in the Netherlands with an Extension towards Electric Vehicle Batteries*. Amsterdam: University of Amsterdam.
- Vermeulen, I., Helmus, J., Lees, M., & van den Hoed, R. (2018). Simulation of Future Electric Vehicle Charging behavior.
- Wolbertus, R., van den Hoed, R., Kroesen, M., & Chorus, C. (2019). Expanding charging infrastructure for large scale introduction of electric vehicles.