

Auteur dr. ir. Robbert-Jan Dikken, Researcher Peutz

Machine learning en data science voor klimaatinstallaties

In de huidige maatschappij zijn data science en machine learning een prominente rol in gaan nemen door de toenemende beschikbaarheid van data en reken capaciteit [1,2]. Binnen verschillende sectoren wordt dit al uitgebreid geïutiliseerd, zoals bijvoorbeeld in de medische, logistieke en financiële sector. Binnen de installatietechnieksector is de toepassing voorsnog beperkt. Opvallend aangezien de toepassing van sensoren in combinatie met machine learning-algoritmes grote potentie biedt voor de optimalisatie van de aansturing van installaties. In dit artikel wordt inzicht gegeven in de potentie van machine learning voor zelflerende regelingen van klimaatinstallaties.

Klimaatinstallaties in een gebouw (utiliteit of woningbouw) hebben tot doel een bepaald comfortniveau voor de gebruikers van het gebouw te faciliteren. Met de regelingen van de klimaatinstallaties wordt beoogd dit zo efficiënt mogelijk te doen met betrekking tot het energiegebruik van de installaties. Dit is zowel in theorie als in de praktijk geen eenvoudige opgave. De doelstellingen comfort en energetische efficiëntie kunnen regelmatig met elkaar in conflict zijn. In het stookseizoen is bijvoorbeeld ventilatie vanwege comfort gewenst, maar heeft dit een nadelig effect op het energiegebruik voor verwarming [3]. Daarnaast wordt de energetische efficiëntie van het systeem beïnvloed door zowel interne effecten zoals gebruikersgedrag als externe effecten zoals weersomstandigheden. Het is daarom een constante zoektocht naar slimmere manieren om de klimaatsystemen efficiënter te regelen.

Machine learning en klimaatinstallaties

Binnen de bouwfysica zijn verschillende toepassingen van machine learning en data science denkbaar [4]. Juist ook op het snijvlak van installatietechniek en bouwfysica bieden machine learning en data science door het conceptuele en multidisciplinaire karakter een toegevoegde waarde. Veel conventionele regelsystemen hebben een reactief karakter, waarbij kennis uit het verleden en verwachte situaties in de toekomst maar beperkt worden meegenomen. Met machine learning en data science is het mogelijk om anticiperende systemen te ontwikkelen. Effecten van zowel interne als externe invloeden op de prestaties van een systeem kunnen met sensoren gemonitord worden. Op basis van deze data kunnen door machine learning-algoritmes verbanden en patronen ontdekt en toegepast worden om optimale regelstrategieën te bepalen, afhankelijk van de (verwachte) omstandigheden en huidige situatie van het systeem.

In een ideale situatie vindt er communicatie tussen alle verschillende componenten van gebouwinstallaties plaats en wordt het systeem integraal geregeld. Voorsnog is dit echter door zowel theoretische als pragmatische obstakels niet haalbaar. Theoretisch gezien is optimaliseren met meerdere doelstellingen, zoals energiezuinigheid en comfort, een gecompliceerd mathematisch probleem, waarbij prioriteit van de verschillende doelstellingen meegewogen dient te worden. Praktisch gezien is de informatie-uitwisseling tussen verschillende onderdelen in het systeem vaak lastig door gebruik van verschillende protocollen. Echter, ook voor individuele componenten blijft de zoektocht naar slimmere regelingen en is er door gebruik van machine learning winst te behalen, zoals in dit artikel zal worden geïllustreerd.

Artificiële neurale netwerken en zelflerende regelingen

Het principe van machine learning is dat algoritmes op basis van data leren, waardoor ze "slimmer" worden en de voorspellende kracht verbetert. Veel machine learning-algoritmes maken gebruik van artificiële neurale netwerken (ANN). Artificiële neurale netwerken zijn gebaseerd op de informatieverwerking in biologische neurale netwerken, oftewel hersenen, en kunnen

relaties tussen input en output leren [5]. Het is een netwerk waarin neuronen met elkaar in verbinding staan, zoals schematisch is weergegeven in Figuur 1. Ieder neuron kan beschouwd worden als een wiskundige functie f en krijgt informatie x binnen vanuit de voorgaande laag neuronen. Per input geldt er een weging w die de specifieke verbinding tussen twee neuronen representeert. Op basis van de gewogen som van alle uitgaande informatie van de neuronen in de voorgaande laag wordt het outputsignaal $y = f(\sum_i w_i x_i)$ van een neuron berekend. Het geheel van de verwerking van de inputsignalen van alle neuronen in het netwerk representeert een bepaalde mathematische functie die voor elk specifieke probleem anders is.

Door mathematische bewerkingen kan het netwerk uit data de relatie tussen input en output leren. Hierdoor zijn neurale netwerken uitermate geschikt om de lerende kern van zelflerende regelingen te vormen door het effect van bepaalde regelstrategieën te voorspellen en hiermee te optimaliseren.

Om de relatie tussen input en output te leren moet een neuraal netwerk eerst getraind worden. Een trainingsalgoritme dat veel wordt toegepast is het backpropagation-algoritme. Hierin wordt gebruik gemaakt van een dataset met bekende input en output. De weegfactoren tussen de neuronen worden zo aangepast dat het netwerk een output berekent die de bekende target output benadert. Initieel is de fout tussen netwerk output en target groot. Tijdens training reduceert de fout en convergeert de oplossing naar een optimum zodat de fout binnen een bepaalde marge valt.

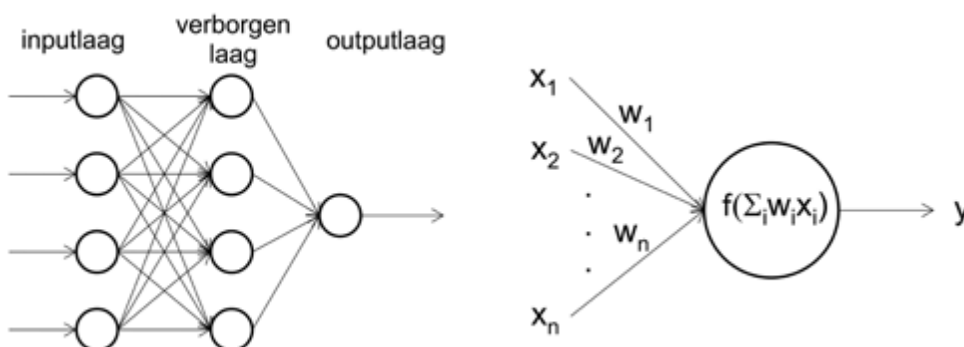
Het neuraal netwerk wordt gebruikt om voor verschillende regelstrategieën het effect te voorspellen (bijvoorbeeld te voorspellen hoe goed een gewenste temperatuur wordt

benaderd) en op basis van deze voorspelling wordt de beste strategie gekozen. Doordat de strategie wordt uitgevoerd komt er nieuwe data beschikbaar waarmee het neuraal netwerk verder getraind kan worden. Hierdoor worden nieuwe gebeurtenissen of veranderende situaties direct geïmplementeerd in de regeling. De regeling leert zo steeds beter wat de regelstrategie is die het meest energetisch optimaal aansluit bij de gewenste comforteisen afhankelijk van de verwachte omstandigheden en de toestand van het systeem. Deze conceptuele methodiek is breed toepasbaar en kan betrekking hebben op een enkele installatie of op een systeem van installaties. Afhankelijk van het vraagstuk en de situatie kan een specifiek optimalisatie-algoritme worden gekozen.

Dynamische energiemodellen

Voor de ontwikkeling van zelflerende regelingen is bepaalde voorkennis nodig: er moet bepaald worden wat de dominante parameters zijn, hoe het ontwerp van de regeling eruit moet komen te zien en de regeling moet worden getest. Hiervoor wordt gebruik gemaakt van dynamische energiemodellen, gesimuleerd in TRNSYS/TRNFlow, waarmee per tijdstap de energiestromen in een gebouw inzichtelijk kunnen worden gemaakt. Bronnen van warmteproductie (zoals zoninstraling, omgevingstemperatuur en interne warmtelasten) en warmteverliezen (zoals transmissie, ventilatie en infiltratie) kunnen in detail worden gemodelleerd. Daarnaast worden in deze modellen de luchtstromingen ten gevolge van ventilatie en infiltratie daadwerkelijk in detail gemodelleerd in plaats van opgedrukt zoals in veel gebouwmodellen het geval is. Met dergelijke dynamische energiemodellen is het energiegebruik veel nauwkeuriger in kaart te brengen dan met de gangbare statische berekeningen.

Een ander voordeel van dynamische energiemodellen is dat ze kunnen worden gebruikt om de zelflerende regelingen te trainen alvorens in de praktijk te worden toegepast. Waar zonder



Figuur 1: Schematische weergave van een feedforward artificieel neuraal netwerk en van een enkel neuron.

voortraining een inregeltijd van circa een jaar nodig zou zijn, vergelijkbaar met de huidige conventionele regelingen, wordt dit nu beperkt tot typisch een maand. De regeling kan vervolgens op locatie in de praktijk verder leren om verder te optimaliseren.

De potentie van machine learning: lucht-water-warmtepomp en vloerverwarming

De potentie van machine learning binnen de installatietechniek komt heel duidelijk naar voren in een specifiek voorbeeld waarbij een lucht-water-warmtepomp in combinatie met vloerverwarming in een woning is geïnstalleerd. De toepassing van een dergelijk systeem in een woning heeft betrekking op een complex vraag-en-aanbod-vraagstuk van warmte. Een vloerverwarmingssysteem is door de massa van de vloer traag, waardoor rekening moet worden gehouden met een lange opwarmtijd. Tegelijkertijd is de opgewekte warmte van een conventionele lucht-water-warmtepomp sterk afhankelijk van de buitenluchttemperatuur. Bij lage buitenluchttemperaturen wordt de toepassing van deze warmtepomp energetisch ongunstiger. Deze twee factoren leiden ertoe dat in veel gevallen de geïnstalleerde warmtepomp sterk overgedimensioneerd is om de kans van het niet kunnen voldoen aan de warmtevraag te reduceren [6]. De dimensionering is echter gebaseerd op het meest nadelig denkbare scenario, waarin geen informatie over het systeem, de omgeving en de verwachte omstandigheden wordt geïutiliseerd.

Een grotere warmtepomp betekent grotere investeringskosten en over het algemeen een hoger energiegebruik. Een slimmere regeling met machine learning kan bepalen op welke momenten moet worden verwarmd om op de juiste tijden de gewenste temperatuur in de woning te halen. Impliciet leert de slimme regeling gebruikmakend van een machine learning-algoritme het effect van de strategie in relatie tot externe factoren en het gebruikersgedrag. Het gebruikersgedrag is in de werkelijkheid niet perfect voorspelbaar, maar de toepassing van sensoren maakt veel mogelijk. Wanneer het gebruikersgedrag of de samenstelling of bezetting van de woning verandert wordt dit gedetecteerd en leert de regeling in te spelen op de nieuwe situatie. Hierdoor is het mogelijk dat met een kleinere warmtepomp aan de comfortvraag kan worden voldaan en tegelijkertijd ook een reductie in energiegebruik kan worden bewerkstelligd.


Als uitgangspunt is gekozen voor een RVO tussenwoning (model met 7 zones) met een 4-persoongezin waarvan de ouders werken (1,5 fte) en de kinderen schoolgaand zijn. Het gedrag van een dergelijk gezin is gesimuleerd met een gedragsmodel op basis van statistische data [7]. Het gegenereerde semi-stochastische gedragsprofiel, welke betrekking heeft op aanwezigheid, CO₂-productie en interne warmtelasten, wordt als input gebruikt voor het dynamisch energiemodel. De gewenste temperatuur in de woonkamer varieert tussen de 18 °C en de 21 °C afhankelijk van het moment van de dag.

Om het effect van het toepassen van een zelflerende regeling van een warmtepomp in combinatie met een lage temperaturen-warmteafgiftesysteem inzichtelijk te maken worden vier situaties vergeleken:

1. Tijdgestuurde warmtepomp met hoog vermogen (vermogen conform ISSO 51: P_0 , een uur voor setpointverhoging verwarmen, een uur voor setpointverlaging stoppen);
2. Tijdgestuurde warmtepomp met laag vermogen (40% P_0 , drie uur voor setpointverhoging verwarmen);
3. Warmtepomp met laag vermogen (40% P_0) zonder verlaging van gewenste temperatuur;
4. Warmtepomp met laag vermogen (40% P_0) met zelflerende regeling.

Op basis van een ruwe berekening met als uitgangspunt ISSO 51 [6] is het vermogen van de warmtepomp P_0 bepaald op 8 kW. Met de bovenstaande scenario's wordt de vraag "Is het mogelijk om met een kleiner opgesteld vermogen aan de comfortvraag te voldoen en tegelijkertijd het energieverbruik voor verwarming te minimaliseren?" beantwoord.

In de zelflerende regeling, ontwikkeld in MATLAB en gekoppeld met het TRNSYS model, zijn de weersverwachting inclusief een kleine random fout, de huidige systeemwaarden (e.g. zonetemperaturen, CO₂-concentratie, ventilatiestand) en de gewenste binnenluchttemperatuur 10 uur vooruit opgenomen. Het neurale netwerk doet een voorspelling van het effect van verschillende strategieën, i.e. verschillende inschakeltijden van de warmtepomp. Op basis hiervan wordt de meest optimale regelstrategie van de warmtepomp bepaald die zowel energetisch als comforttechnisch naar verwachting het beste is. Vervolgens wordt gemonitord wat het effect van



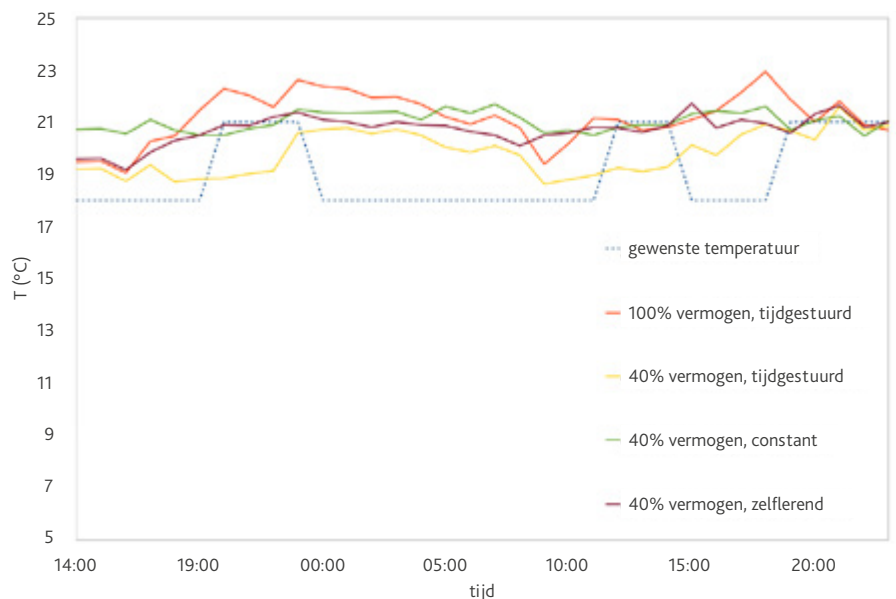
Figuur 2: De door de getrainde regeling voorspelde temperatuur uitgezet tegen de werkelijke temperatuur in tijdsintervallen van 1 tot 10 uur.

de regelstrategie is en wordt hiermee het neurale netwerk verder getraind, wat inhoudt dat het neurale netwerk de relatie tussen de weersverwachting, de huidige systeemwaarden, regelstrategie en het temperatuurverloop leert.

In Figuur 2 is de door de regeling voorspelde temperatuur in de woonkamer (voor zowel de zomerperiode als het stookseizoen) uitgezet tegen de werkelijke temperatuur (na training over beide seizoenen). Het betreft hier nieuwe situaties die (nog) niet expliciet in de training van het neurale netwerk zijn opgenomen. De regressielijn in Figuur 2 laat zien dat het neurale netwerk zeer goed in staat is voor verschillende nieuwe situaties de temperatuur te voorspellen voor tijdsintervallen tussen de 1 en 10 uur.

In Figuur 3 is een illustratief voorbeeld van het temperatuurverloop in een ruimte voor de verschillende situaties weergegeven samen met de gewenste temperatuur. Het toont dat de warmtepomp met 100% vermogen wel de gewenste temperatuur haalt, maar ook dat de temperatuur nog redelijk frequent ver voorbij de gewenste temperatuur schiet. De tijdgestuurde warmtepomp met 40% vermogen toont significante onderschrijding. De warmtepomp met 40% vermogen waarvoor een constante temperatuur is gezet toont geen relevante onderschrijding, maar uiteraard ook geen significante verlaging op momenten dat de gewenste temperatuur lager ligt. De zelflerende regeling optimaliseert op zo weinig mogelijk over- en onderschrijding.

Figuur 3: Voorbeeld van het temperatuurverloop in een ruimte voor warmtepompen met een verschillend vermogen en verschillend type regeling (tijdens stookseizoen).



Voor alle situaties bestaat er altijd een kans dat er een mate van onderschrijding plaatsvindt. In Tabel 1 is het energiegebruik en de kans op en mate van onderschrijding voor de verschillende situaties weergegeven. Uit de simulaties blijkt dat in de conventionele situatie, waarbij een vermogen conform de ISSO 51 wordt geïnstalleerd, er een kans van 6% op onderschrijding is. Voor de situatie met de kleinere warmtepomp met enkel tijdsturing wordt de kans op onderschrijding twee keer zo groot en kan dus duidelijk niet met een kleiner opgesteld vermogen aan de comfortvraag voldaan worden. De gangbare methode om toch met een kleinere warmtepomp aan de comfortvraag te voldoen is om de temperatuur constant te houden. Dit leidt inderdaad tot een vergelijkbaar comfortniveau vergeleken met een groter opgesteld vermogen. Echter, er wordt ook op momenten dat er geen vraag is verwarmd. De zelflerende regeling leert het effect van verschillende strategieën en past op basis van een

Type regeling	Tijdstuur	Tijdstuur	Constant	Zelflerend
Vermogen	100% P ₀	40% P ₀	40% P ₀	40% P ₀
Energiegebruik (t.o.v. 100% P ₀)	100%	78%	93%	83%
Kans onderschrijding	6%	12%	6%	6%
Gemiddelde onderschrijding	0,7°C	1,1°C	0,6°C	0,6°C
Maximum onderschrijding	3,7°C	5,1°C	2,9°C	2,9°C

Tabel 1: Samenvattende vergelijking van het energiegebruik en de onderschrijdingen voor de vier scenario's met warmtepompen met een verschillend vermogen en verschillend type regeling.

voorspelling de meest optimale strategie toe. Uit de simulaties blijkt dat de toepassing van een zelflerende regeling leidt tot een vergelijkbaar comfortniveau terwijl het geassocieerde energiegebruik significant gereduceerd is met 17%.

Zelflerende regelingen binnen de utiliteitsbouw

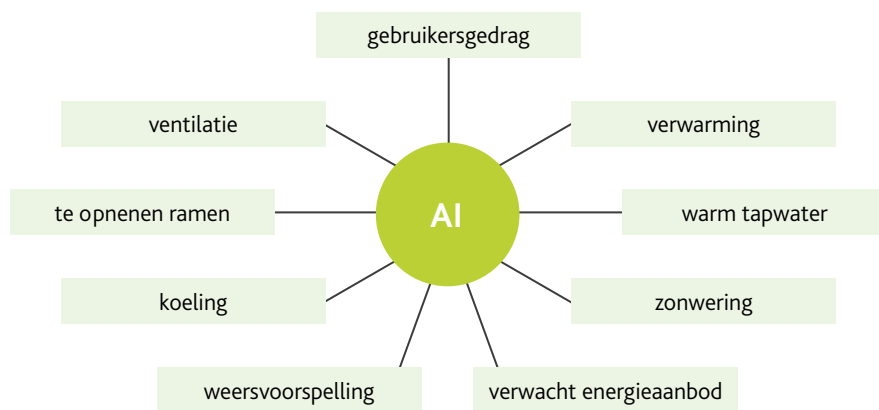
Het voorbeeld dat in de vorige sectie is uitgewerkt is een typisch vraagstuk dat zich in de woningbouw kan voordoen. Ook binnen de utiliteitsbouw bieden data science en machine learning interessante mogelijkheden. Hierbij kan worden gedacht aan verschillende toepassingen. Een voorbeeld is de sturing op de bezetting in kantoorgebouwen. In grote kantoorgebouwen is vaak de bezetting niet 100%. Zeker vergaderruimtes zijn vaak niet volcontinu bezet. Door vergaderschema's en installatieregelstrategieën integraal te benaderen en te combineren met het thermische gedrag van het gebouw kan geoptimaliseerd worden op energiegebruik ten behoeve van

comfort. Een machine learning-algoritme kan het thermisch gedrag van het gebouw onder invloed van de externe invloeden (weer etc.) en interne invloeden (gebruikersgedrag en regelstrategieën) leren. Vervolgens kan dit algoritme voorspellen wat het energiegebruik zal zijn voor verschillende invullingen en voorwaarden van het gebouw. Zo kan het bijvoorbeeld zijn dat het in de ochtend optimaal is om vergaderkamer 1 te gebruiken terwijl het in de middag optimaal is om vergaderkamer 2 te gebruiken (wanneer ze niet beiden bezet zijn uiteraard). De sturende werking hoeft uiteraard niet absoluut te zijn. Het is heel goed mogelijk om menselijke feedback of tussenkomst te implementeren in een dergelijk systeem. Wel dient hierbij bedacht te worden dat menselijke tussenkomst een suboptimaal functioneren kan betekenen. Dit dient derhalve ook meegewogen te worden in het lerende karakter van het systeem, zodat het systeem ook leert herkennen waar bepaalde effecten vandaan komen.

Een ander voorbeeld waarbij machine learning uitkomst kan bieden is in de optimalisatie van de aansturing van luchtbehandelingsinstallaties (verwarming, ventilatie en airconditioning). Hoe complexer een systeem, dus hoe meer componenten en variabelen er in een systeem aanwezig zijn, hoe waarschijnlijker het is dat een machine learning-algoritme beter kan optimaliseren dan de mens. In algemeenheid kan worden gesteld dat met toepassing van machine learning-algoritmes beter afgewogen keuzes gemaakt kunnen worden over de inzet van installaties in gebouwen.

Machine learning heeft de toekomst

Machine learning biedt vele mogelijkheden voor toepassing binnen de installatietechniek. De eerste stappen zijn gezet om de economische en pragmatische voordelen qua optimalisatie van installatieconcepten met machine learning in de praktijk te tonen. Naar verwachting zal in de toekomst machine learning een belangrijke plaats gaan innemen binnen de installatietechniek, zoals dat al voor verschillende sectoren het geval is. Een mogelijk toekomstbeeld is één waarin



Figuur 4: Voorbeeld van een installatieregelconcept van de toekomst.

alle installaties in een gebouw zijn gekoppeld en met elkaar communiceren, zoals in Figuur 4 weergegeven. Een systeem met artificiële intelligentie en een machine learning-kern geeft sturing aan het gehele installatiesysteem, waarin weersvoorspelling en gebruikersgedrag zijn geïntegreerd. Door continu te leren van het eigen functioneren kan het systeem optimaliseren op energiegebruik en comfort. Een dergelijk systeem kan verbanden tussen de veelvoud aan operaties in relatie tot de omstandigheden beter herkennen dan een mens en kan hierdoor efficiënter regelen.

Om de kracht van machine learning te illustreren is in dit artikel een voorbeeld van een zelflerende regeling voor de aansturing van een lucht-water-warmtepomp behandeld. Hiermee kan een behoorlijke reductie van zo'n 17% in energiegebruik worden bewerkstelligd door op gunstige momenten warmte te winnen. Door meerdere aspecten van installaties te koppelen en hierin slim te regelen is de verwachting dat de energiebesparing nog groter kan worden.

De noodzaak om op gunstige momenten energie te gebruiken wordt steeds dringender door de verschuiving van fossiele naar duurzame energiebronnen. Deze verschuiving naar duurzame energiebronnen betekent ook een verandering in vraag en aanbod van energie en de energiemarkt zelf. Doordat het aanbod van

energie aanzienlijk meer stochastisch wordt vergeleken met het verstoken van fossiele brandstoffen ontstaat de noodzaak om slimmere keuzes te maken over de momenten waarop energie wordt gebruikt. Het is mogelijk om voorspellingen te doen van het verwachte energieaanbod. Een voorbeeld hiervan is onderzoek door Deepmind dat een algoritme heeft getraind om de verwachte energieopbrengst van een windmolenpark voor de komende 36 uur te voorspellen [8]. Iets dergelijks kan ook met het collectief aan zonnepanelen dat op gebouwen ligt. Met de kennis over het verwachte aanbod door gebruik van machine learning-algoritmes kan in gebouwregelingen anticiperend worden opgetreden om aan de energievraag te kunnen voldoen.

Conclusie

Data science en machine learning bieden een gigantische potentie voor de installatietechniek. Fysische modellen hebben hierin een belangrijke, faciliterende rol. De komende jaren zal moeten blijken hoe de potentie het best te verwezenlijken is. Maar het leidt geen twijfel dat het een kwestie van tijd is voordat deze technieken hun intree doen om de nieuwe uitdagingen die er liggen op het gebied van duurzaamheid op te lossen.

Referenties

- [1] Kool, L., Timmer, J., van Est, R., De datagedreven samenleving - Achtergrondstudie, Den Haag, Rathenau Instituut (2015).
- Position Paper – Taskforce AI, 'Algoritmen die werken voor iedereen, samen bouwen aan onze (digitale) toekomst met Artificiële Intelligentie' (18 juli 2019).
- VLA methodiek gelijkwaardigheid voor energiebesparende ventilatieoplossingen in woningen, versie 1.3 (2018).
- Dikken, R.J., Introductie in machine learning en data science voor toepassing binnen de bouwfysica, Bouwfysica 3 (2018).
- Mitchell, T.M., Machine Learning, The McGraw-Hill Companies, Inc. (1997).
- SSO-publicatie 51 'Warmteverliesberekeningen voor woningen en woongebouwen' (2017).
- Aerts, D., Occupancy and activity modelling for Building Energy Demand Simulations, Comparative Feedback and Residential Electricity Demand Characterisation, Vrije Universiteit Brussel, PhD dissertatie (2015).
- <https://deepmind.com/blog/machine-learning-can-boost-value-wind-energy/>



dr. ir. Robbert-Jan Dikken,
Researcher Peutz