

Machine learning voor een betere comfortbeleving en lager energiegebruik


Een van de belangrijkste toekomstige uitdagingen in de gebouwde omgeving is het bereiken van een goed thermisch comfort met een minimum aan energiegebruik. Vermindering van het energiegebruik van klimaatinstallaties is cruciaal bij de vermindering van de effecten van de opwarming van de aarde. Maar klimaatinstallaties zijn onmisbaar om gezonde en comfortabele omstandigheden te maken met betrekking tot de binnencondities in gebouwen. Het waarborgen van een hoog niveau van thermisch comfort voor de gebruikers van het gebouw is van essentieel belang, voor met name de productiviteit.

In het kader van de strategische samenwerking EuroTech van de TU Eindhoven met de technische universiteiten van Kopenhagen, München en Lausanne is in 2014 een onderzoek gestart met steun van het Nederlandse bedrijfsleven vertegenwoordigd door Opleidings- en ontwikkelingsfonds voor het Technisch Installatie Bedrijf ('OTIB') en Stichting Promotie Installatietechniek ('PIT'). De resultaten daarvan worden hier beknopt weergegeven.

Om het energiegebruik te verminderen en gelijktijdig het thermisch comfort te verbeteren, is onderzoek gedaan naar gepersonaliseerd thermisch comfort en daarop afgestemde individuele comfortsystemen. De focus van de theoretische benadering is hierbij verschoven van de beleving van een gemiddelde persoon naar hoe een individuele persoon zijn



"Artificial Intelligence, deep learning, machine learning - whatever you're doing if you don't understand it - learn it. Because otherwise you're going to be a dinosaur within 3 years." - Mark Cuban, American entrepreneur

of haar persoonlijke comfort ervaart. Dit kan worden gerealiseerd met conditionering met behulp van persoonlijke conditioneringssystemen (PCS). Persoonlijk conditioneringssystemen vormen een veelbelovende oplossing voor twee grote uitdagingen: het hoge energieverbruik van de gebouwen en een nog steeds slechts middelmatig ervaren thermisch comfort. Deze systemen maken het mogelijk om een micro-omgeving te conditioneren aangepast op de voorkeur van de individuele gebruiker. Hierdoor kan aan individuele wensen voor thermisch comfort worden voldaan en kan ook energie worden bespaard door een hogere effectiviteit in vergelijking met de traditionele klimaatsystemen. In deze studie twee aspecten is persoonlijke verwarming en de effectiviteit van verschillende rege-



Model predictive control van persoonlijke verwarming - experimentele opzet in de klimaatkamer

Figuur 1: Persoonlijk verwarmingssysteem om verschillende regelstrategieën voor het thermisch comfort uit te proberen.



Figuur 2. Schematische weergave van het thermofysiologische model.


lingen onderzocht en bouwt voort op onderzoek van Michal Veselý (2017) en Jacob Verhaart (2018). De gebruikte laboratorium opstelling is weergegeven in figuur 1.

Eerdere studies toonden aan dat individuele verschillen zoals geslacht, lichaamssamenstelling en leeftijd verschillende fysiologische reacties veroorzaken bij individuen in dezelfde thermische omgeving. De persoonlijke beoordelingen van proefpersonen geven aan dat gemodelleerde fysiologische reacties met behulp van thermofysiologische modellen waardevol zijn voor het voorspellen van individueel ervaren thermische sensatie.

In het eerste deel van het onderzoek is op basis van een literatuurstudie het verloop van de ontwikkeling van de thermo fysiologische modellen, zie figuur 2, vastgesteld en hun rol voor het modelleren van thermisch comfort in gebouwen.

Het tweede deel was gericht op het uit de meetdata afleiden van een gepersonaliseerd voorspellend model voor het regelen van een dergelijk systeem. De lokale huidtemperaturen werden gebruikt als input voor thermische sensatie modellen en zo meegenomen bij het modelleren van de regeling voor het PCS, zie figuur 3.

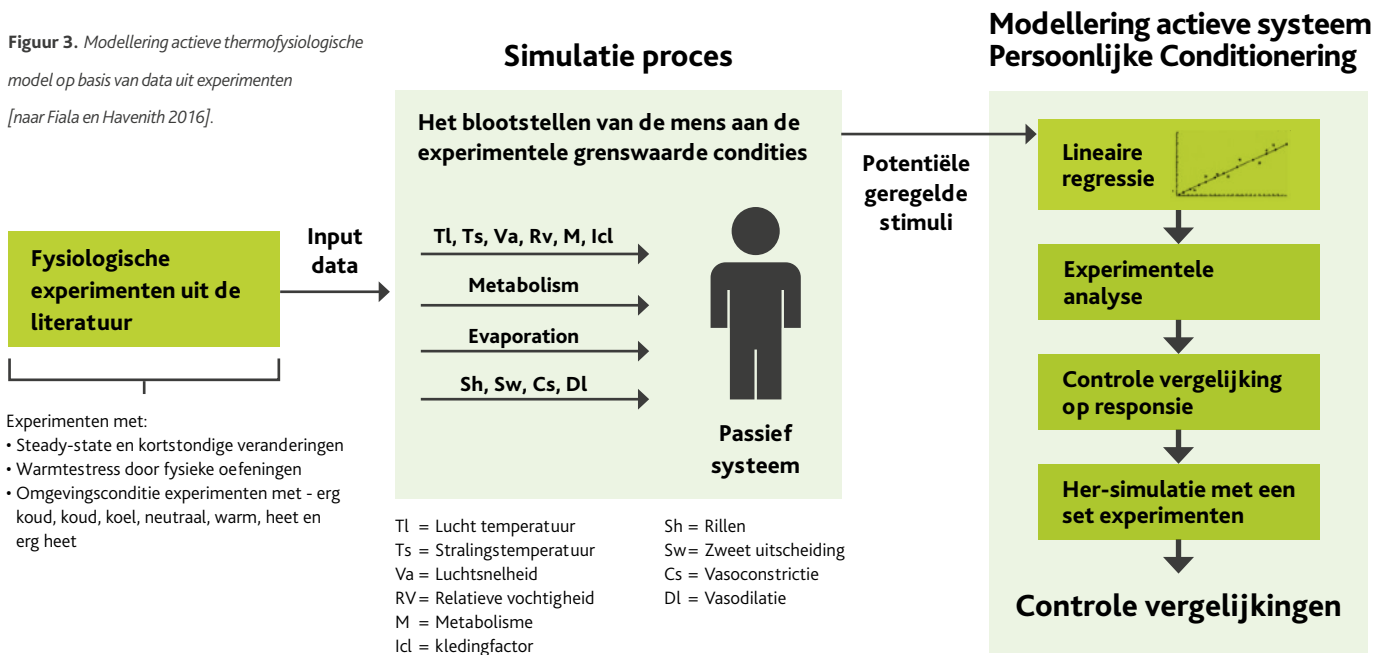
Er is een thermofysiologisch model van een hand ontwikkeld om dat uit eerder onderzoek is gebleken dat dit lichaamsdeel het snelst reageert om wijzigingen in de omgevingstemperatuur. Door de huidtemperatuur van de hand te modelleren was het mogelijk om de samenhang te onderzoeken tussen de lokale lichaamstemperaturen, de bloedstroom en lichaamssamenstelling. Huidtemperaturen van de handen van verschillende individuen werden gesimuleerd en de resultaten werden gevalideerd met experimentele gegevens uit de literatuur. Verschillende lichaamssamenstellingen resulteerden in verschillende lokale huidtemperaturen. De lokale huidtemperaturen werden gebruikt als input voor thermische sensatie modellen en zo meegenomen bij het modelleren van de regeling voor het PCS.



Het tweede deel was gericht op het uit de meetdata afleiden van een gepersonaliseerd voorspellend model voor het regelen van een dergelijk systeem. Hierbij is gebruik gemaakt van de ontwikkelingen van voorspellende modellen met behulp van machine learning algoritmen, zoals neurale netwerken.

Machine learning is ontwikkeld op basis van het vermogen om computers te gebruiken om data op patronen te herkennen uit de beschikbare data. Het programma krijgt de data (de input) aangeboden en zoekt het zelfstandig naar een manier om tot een zo passend mogelijk verband tussen de gegevens te komen (de output). Hierbij worden statistische technieken toegepast bij het zoeken naar het beste patroon. Dit kan bijvoorbeeld (lineaire) regressie zijn, maar ook meer complexe benaderingen. Het programma genereert vervolgens een code die dat patroon kan herkennen: het model. Dit is de implementatie van een algoritme (instructies) voor het herkennen van een patroon. Het model kan het gevonden patroon vervolgens gebruiken om voorspellingen te doen. Er zijn verschillende methoden bij machine learning die allen hetzelfde doel hebben. Namelijk om te komen tot inzichten, patronen en relaties die kunnen worden gebruikt om beslissingen te nemen. De meest gebruikte methoden van machine learning zijn [3BPlus 2017];

Figuur 3. Modelleren actieve thermofysiologische model op basis van data uit experimenten
[naar Fiala en Havenith 2016].




- **supervised learning:** hierbij is het doel een algemene regel te leren, op basis van voorbeeldinput en de gewenste output, die de gegeven input vertaalt naar deze gewenste output. Het systeem leert hiermee de verbanden tussen de input en de output.
- **unsupervised learning:** in dit geval gaat het om ongecontroleerd leren, waarbij geen sturing wordt geboden door voorbeelden in te voeren met een gewenste output. Het leeralgoritme is op zichzelf aangewezen om structuur te vinden in de input en met de passende output komen. De input wordt verdeeld in categorieën, waarin de elementen geplaatst worden met gegevens die sterk op elkaar lijken.
- **semi-supervised learning:** wordt in principe voor dezelfde toepassingen als supervised learning gebruikt. Er wordt gebruik

gemaakt van zowel voorbeeld input als ook niet voor- gesorteerde data voor training – meestal een kleine hoeveelheid data om van te leren met een groot aantal onbekende data voor de validatie.

- **reinforcement learning:** hierbij zijn er hoofdcom- ponenten: de beslisser, de omgeving en acties. Het programma navigeert in een dynamische omgeving waarin het een bepaald doel moet uitvoeren, zoals het spelen van een spel. Het doel is om acties te kiezen die de verwachte beloning over een bepaalde tijd maxi- maliseren. Het doel wordt veel sneller bereikt door een

Figuur 4. Opzet voor het gebruik van Machine Learning voor de bepaling van de meest geschikte thermisch comfort instelling bij individuele verwarming.




goed algoritme te gebruiken. Oftewel: het doel bij reinforcement learning is om het beste algoritme te bepalen. Door trial and error wordt nagegaan welke acties de grootste beloningen opleveren. Reinforcement leren wordt vaak gebruikt voor robotica, gaming en navigatie.

- **deep learning:** heeft als doel om machine learning dichterbij echte Artificial Intelligence te brengen door de inzet van diepe neurale netwerken. Dit zijn neurale netwerken met meerdere verborgen lagen tussen de input- en outputlagen. Het grote aantal lagen maakt complexe transformaties mogelijk die latente structuren ontdekken binnen ongestructureerde en ongelabelde data. Het gaat om het ontdekken van onbekende patronen in de gegevens.

In een eerste reeks experimenten werden gegevens verzameld voor het trainen en testen van het gepersonaliseerde model waarbij de proefpersonen zelf de verstelling van de instelling deden. In de tweede reeks experimenten werden de ontwikkelde neurale netwerkmodellen in de regeling geïmplementeerd. De gepersonaliseerde verwarmingsinstellingen werden voorspeld en de resultaten met de automatische regeling daarvan werden geëvalueerd, zie figuur 4.

De resultaten tonen een hoge nauwkeurigheid bij het voorspellen van verwarmingsinstellingen met de implementatie van de machine learning technieken in de regelingen. Het onderzoek toont aan dat de gebruiker een beter ervaren thermisch comfort kan krijgen met een lager energiegebruik met behulp van PCS, zie figuur 5 waar het verschil tussen twee proefpersonen is aangegeven. Meer informatie is te vinden in Katić (2019).

Meer informatie is te vinden bij de onderstaande referenties.



Figuur 5. Maximum, minimum en gemiddeld energie gebruik bij bediening door de gebruiker en bij de voorspellende automatische regeling op basis van machine learning voor twee verschillende proefpersonen A en B op basis van langdurige metingen.

Referenties

1. M. Veselý, P. Molenaar, M. Vos, R. Li, W. Zeiler, 2017, Personalized heating - Comparison of heaters and control modes, *Building and Environment* 112: 223-232
2. J. C. G. Verhaart, R. Li, W. Zeiler, 2018, *Science and Technology for the Built Environment*. 24(1): 57-72. <http://eurotech-universities.eu/>
3. D. Fiala, G. Havenith, 2016, *Modelling Human Heat Transfer and Temperature Regulation*, in *Studies in Mechanobiology, Tissue Engineering and Biomaterials*, Springer-Verlag Berlin Heidelberg.
4. K. Katić, R. Li, and W. Zeiler, "Thermophysiological models and their applications: A review", *Building and Environment* 106 (2016): pp. 286-300
5. K. Katić, R. Li, B.R.M. Kingma, and W. Zeiler, "Modelling hand skin temperature in relation to body composition", *Journal of Thermal Biology* 69 (2017): pp. 139-148
6. K. Katić, R. Li, J. Verhaart, and W. Zeiler, "Neural network based predictive control of personalized heating systems", *Energy and Buildings* 174 (2018): pp. 199-213
7. K. Katić, Towards individual thermal comfort: Model predictive personalized control of heating systems, PhD thesis, TU Eindhoven (2019), <https://research.tue.nl/en/publications/towards-individual-thermal-comfort-model-predictive-personalized>
8. 3BPlus, 2017, Hoe werkt machine learning – machine learning uitgelegd, <https://3bplus.nl/hoe-werkt-machine-learning-machine-learning-uitgelegd/>