

Auteurs

Dr.ir. Kees Wisse (senior adviseur DWA); dr.ir. Zara Huijbregts (junior adviseur DWA); dr.ir. Gaby Abdalla (programamanager business development & innovatie DWA), Damiën Horsten MSc (alumnus Rotterdam School of Management / Deloitte Nederland); Jan Mariniak MSc (alumnus Rotterdam School of Management / ThyssenKrupp), dr. Tobias Brandt (assistant professor Rotterdam School of Management)

Energierkening bewaken: algoritmes of simulatiemodellen?

Stel, je bent dertig jaar verantwoordelijk voor de energierekening van een groot pand - en je moet die rekening ook betalen - dan is het belangrijk een tool of methode beschikbaar te hebben om de energierekening te bewaken. Als methode kun je gebruikmaken van kengetallen, fysische simulatiemodellen of van data-getrainde algoritmes. In dit artikel wordt een vergelijking gemaakt tussen de performance van een fysisch simulatiemodel en data-getrainde algoritmes. Hoe goed zijn deze technieken in staat om op 24-uursbasis de warmtevraag te evalueren? En welke techniek komt daarbij als beste uit de bus?

In energieprestatiecontracten kan worden gewerkt met een garantie voor de omvang van de energierekening. Dat maakt het mogelijk om all-inclusive huurcontracten aan te bieden en zo het risico van een hoge energierekening bij de huurder weg te halen. All-inclusive huurcontracten bieden ook de mogelijkheid om de kosten en baten van de besparingsmaatregelen bij één partij neer te leggen en zo een oplossing te bieden voor het zogenoemde 'split-incentive' probleem (wel de kosten, maar niet de baten). In een all-inclusive contract kan door het slim bewaken van de energierekening ruimte ontstaan voor nieuwe investeringen in energiebesparing. Als je de rekening niet slim bewaakt, constateer je na een aantal jaren dat de energierekening toch veel hoger is dan gedacht, waardoor het rendement van eerder gedane investeringen sterk onder druk komt te staan.

In eerdere publicaties is aandacht besteed aan de mogelijke bijdrage van fysische simulatiemodellen aan het (vooraf) garanderen van de energierekening [1, 2]. Door de snelle opkomst van

kunstmatige intelligentie is het echter ook interessant te weten wat datage trainde algoritmes kunnen betekenen voor het garanderen van de energierekening. Kunnen slimme algoritmes het energiegebruik bewaken? En zo ja, hoe presteren die dan in vergelijking met fysische simulatiemodellen? Om op deze vragen antwoord te krijgen, heeft DWA samen met Rotterdam School of Management onderzoek gedaan naar de toepasbaarheid van algoritmes en neurale netwerken [3, 4]. Dit artikel presenteert de uitkomst hiervan in vergelijking met de resultaten van fysische simulatiemodellen.

Kengetallen schieten te kort

Voor het bewaken van de energierekening kan natuurlijk worden gebruikgemaakt van kengetallen en bijvoorbeeld correcties op basis van zogenoemde graaddagen. Het concept van graaddagen is echter maar zeer beperkt bruikbaar voor het evalueren van de energievraag en het vroegtijdig signaleren van afwijkingen. Wat de warmtevraag betreft: graaddagen houden alleen rekening met de buitentemperatuur. Zonbelasting en de interne warmteproductie moet je dan corrigeren met de weegfactor voor seizoensinvloeden en de stookgrens [5]. Maar wie zal zeggen wat je daar moet invullen? Het blijft een 'educated guess'. Voor koelenergie is het vraagstuk niet goed aan te pakken op basis van dit soort correctiefactoren. Zonbelasting en interne warmtebelasting hebben een te grote invloed op het eindantwoord. Voor de totale energierekening is ook de elektriciteitsrekening, inclusief gebruikersenergie van verlichting en apparatuur, een significante factor. Daarmee kom je in de sfeer van kengetallen niet veel verder dan een verbruik per m² vloeroppervlak.

Bewaken met algoritmes en simulatiemodellen

Als kengetallen onvoldoende zijn om het energiegebruik te bewaken, wat kunnen fysische simulatiemodellen en algoritmes dan betekenen? Het bewaken van de energieprestatie op basis van fysische modellen en algoritmes gaat als volgt. Fysische modellen worden tijdens de eerste periode van het

Kalibreren van fysische modellen

gebouwebruik gekalibreerd op het gebouwgebruik en het gebruik van de installatie (zie Figuur 2 en de paragraaf 'Kalibreren van fysische modellen'). Na de kalibratieperiode geeft het model steeds een 'voorspelling' van het energiegebruik, parallel aan het gemeten verbruik. Op die manier komen afwijkingen aan het licht, bijvoorbeeld als er een reset plaatsvindt van het gebouwbeheersysteem, er setpoints worden gewijzigd of als er faalgedrag van componenten optreedt. Dit concept is een vorm van model-based continuous commissioning (zie onder andere IEA Annex 40 [6]). In dit artikel wordt dit opgesplitst in het gebruik van twee soorten modellen: fysische modellen en modellen in de vorm van een datagetraind algoritme. In een concept van model-based continuous commissioning worden de algoritmes getraind met meetdata gedurende de eerste periode van het gebruik van een gebouw (zie 'Trainen van algoritmes'). Vervolgens worden ze ingezet om de energievraag te bewaken. Parallel aan het gemeten verbruik geeft het algoritme na de trainingsperiode steeds een 'voorspelling' van het energiegebruik (Figuur 1 en Figuur 4).


Voor zowel fysische modellen als algoritmes is het daarbij wel relevant dit te combineren met zogenoemde initial commissioning waarbij de kwaliteit van de bemetering wordt gecontroleerd en de meest basale fouten in het functioneren van de installatie worden gecorrigeerd. Dit dient zo spoedig mogelijk na oplevering te gebeuren, zodat er genoeg tijd beschikbaar is voor het kalibreren en trainen van modellen.

Om meer inzicht in de mogelijkheden te krijgen, wordt eerst de werkwijze van het kalibreren van fysische modellen en het trainen van algoritmes verder toegelicht.

De werkwijze is als volgt: de hele gebouwgeometrie wordt ingevoerd in het simulatiepakket. In het geval van dit artikel betreft het Vabi Elements. Hierbij worden de uitgangspunten voor de gebouwschil, het gebouwgebruik en het gebruik van de installatie ingevoerd (zie bijvoorbeeld ISSO 32 voor een overzicht [7]). Het hele gebouw wordt vervolgens op uurlijkse basis doorgerekend, een werkwijze die op zich bekend is vanuit de veelgebruikte temperatuuroverschrijdingsberekeningen. Het verschil zit onder meer in de volgende elementen:

- De berekeningen worden uitgevoerd op gebouwniveau, in plaats van op het niveau van een individueel vertrek. Meerdere gebouwzones worden hierbij tegelijk doorgerekend.
- In plaats van het standaard klimaatjaar (NEN 5060 referentiejaar energie) worden de data van het werkelijke buitenklimaat van het dichtstbijzijnde station van het KNMI ingevoerd.
- In plaats van de gebruikelijke ontwerpwaarden voor verlichting, apparatuur en personen worden gebruikersprofielen ingevoerd zoals die volgen uit monitoring van het gebouw ('werkelijk gebouwgebruik' Figuur 2).
- Er wordt gebruikgemaakt van de setpoints en bedrijfstijden zoals die volgen uit de monitoring van het gebouw ('werkelijk gebruik installatie' in Figuur 2).
- Eventueel faalgedrag dat kan worden gemodelleerd, wordt ook in het model meegenomen.

Het model wordt dus gekalibreerd door zoveel mogelijk gemeten inputwaardes van het model te hanteren in plaats van ontwerpwaardes. De output van het model wordt geëvalueerd aan de hand van metingen, niet alleen het eindantwoord op jaarbasis, maar ook de hoeveelheden op 24-uursbasis (voor verdere resultaten zie [1]). Op basis hiervan vindt verdere fine-tuning plaats omdat er in bovengenoemde uitgangspunten van het 'werkelijke gebruik' altijd een zekere bandbreedte zit. Daarnaast zijn er uitgangspunten in gebouwsimulatie die je moeilijk met metingen kunt kwantificeren (zoals windafhankelijkheid van de infiltratie).




Figuur 1: Concept: continuous commissioning op basis van modellen en/of algoritmes



Figuur 2: Fysische simulatie-modellen worden gekalibreerd op basis van onder meer het gebouwgebruik en het gebruik van de installatie

Trainer van algoritmes

Machine learning is een snel opkomend vakgebied waar bij andere disciplines snel voortgang in wordt geboekt (robots, zelfrijdende auto's, online marketing). Machine learning maakt gebruik van getrainde algoritmes om patronen in data te herkennen en is daarom bij uitstek geschikt ook grote hoeveelheden data te hanteren. De algoritmes worden getraind met data uit het verleden waarbij bekende input én output aan het algoritme worden aangeboden. Door een groot aantal keer het 'eindantwoord' te vertellen aan het algoritme, 'leert' het algoritme het verband tussen de input en de output (zie Figuur 4). De input betreft in dit geval: weergegevens, het gebouwgebruik en de tijd. De output is dan de warmtevraag of de koudevraag. Als maat voor het gebouwgebruik wordt hierbij gebruikgemaakt van het elektriciteitsgebruik van het gebouw (exclusief de warmteopwekking).



Figuur 4: Werkwijze algoritmes

Algoritmes bestaan er in allerlei 'soorten en maten'. De meest simpele vorm is lineaire regressie. De meest uitgekledede vorm daarvan is weer gewoon een rechte lijn trekken in het platte vlak door een puntenwolk, een techniek die we allemaal wel eens toepassen. In het onderzoek is gebruikgemaakt van zowel lineaire regressie als meer geavanceerde vormen. De lineaire regressie vormt dan een baseline voor de minimale prestatie die een algoritme moet halen. De geavanceerde vormen betreffen zogenoemde gradient boosting en neurale netwerken (zie tekstkader voor meer uitleg) [3, 4].

Samenvatting verschil fysische modellen en algoritmes

Met bovenstaande achtergrondkennis in het achterhoofd kan het verschil tussen fysische modellen en algoritmes als volgt omschreven worden. Bij fysische modellen wordt de achterliggende wiskundige samenhang bepaald door fysische wetten (met betrekking tot energiebalans, warmtegeleiding etcetera). Bij het kalibreren wordt enkel de input veranderd en wordt bepaald in hoeverre de output dan overeen komt met datgene wat gemeten wordt. Voor het overige blijft het wiskundige model van de fysica tijdens het kalibreren ongewijzigd. Bij datage trainde algoritmes wordt de achterliggende wiskundige samenhang bepaald door het type algoritme en door de data die aangeboden wordt bij training van het algoritme. Tijdens het trainen wordt de wiskundige samenhang bepaald die toegepast wordt voor het doen van voorspellingen in nieuwe situaties.

Uitleg algoritmes

Gradient boosting algoritmes

Boosting algoritmes zijn machine learnings algoritmes die 'leren' van de fouten die ze maken. Nu doen de meeste machine learning algoritmes dat, maar boosting algoritmes maken hierbij gebruik van een speciale techniek. Er worden meerdere 'runs' gedraaid met een basisvariant van het voorspellingsmodel en op iteratieve wijze wordt een steeds beter model gebouwd. Het voorspellingsmodel wordt steeds accurater, onder andere door ook de fout van de vorige 'run' te voorspellen. De term 'Gradient' heeft betrekking op de manier waarop gezocht wordt naar de minimale fout.

Neurale netwerken


Neurale netwerken worden zo genoemd omdat ze zijn ontwikkeld in analogie met de werking van de menselijke hersenen. Er is sprake van zogenoemde 'neurons' die met elkaar in verbinding staan en een netwerk vormen. De zogenoemde 'inputlayer' van neurons bestaat uit de inputparameters zoals getekend in Figuur 4. Er is sprake van een 'outputlayer', wat in dit geval de warmtevraag betreft. Al naar gelang de opzet van het neurale netwerk bevinden zich tussen deze twee lagen een aantal 'hidden layers' (Figuur 3).

Black box?

In vergelijking met een fysisch model (white box) worden

algoritmes vaak ook wel bestempeld als 'black box models'.

Je kunt je er geen voorstelling van maken wat er bijvoorbeeld allemaal in de 'hidden layers' van een neuraal netwerk gebeurt. Wel is het mogelijk algoritmes te laten vertellen welke inputparameters er veel of weinig invloed hebben op het eindantwoord. Je kunt bijvoorbeeld een 'top-drie' of 'top-tien' laten berekenen van parameters die een grote impact hebben op het eindantwoord. Op die manier kun je weer wel een relatie leggen met fysische processen en (tot op zekere hoogte) bepalen of het algoritme fysisch relevante resultaten produceert.



Figuur 3: Voorbeeld structuur van een neuraal netwerk [4]

Vraagstelling uitwerking casus

Om de geschiktheid van modellen en algoritmes voor het bewaken van de energieprestatie te beoordelen, is de eerste vraag natuurlijk: hoe nauwkeurig kunnen modellen een evaluatie geven van de energievraag? Als er een grote bandbreedte zit in de voorspelling van de energievraag, dan zou het zo kunnen zijn dat de getekende 'afwijking' in Figuur 1 wegvalt in de onnauwkeurigheid van de voorspelling van het simulatiemodel of algoritme. Dit artikel gaat in op de nauwkeurigheid van de voorspelling door de uitkomst van het fysisch simulatiemodel, het neuraal netwerk en het gradient boosting algoritme te vergelijken aan de hand van een casus. De casus die hier wordt behandeld, betreft een kantoorpand waarvan de warmtevraag wordt geëvalueerd op 24-uursbasis. Er zijn in dit pand energiemeters in de distributienetten. De opwekking van de warmte

en het rendement daarvan vallen daarmee buiten de analyse. Een tweede kanttekening betreft het woord 'voorspelling'. Zowel in het simulatiemodel als in de algoritmes wordt er gebruikgemaakt van bekende weergegevens van het meest nabijgelegen KNMI-station. Er is dus geen sprake van een 'toekomstvoorspelling', maar eigenlijk vindt er een evaluatie plaats van de energievraag op basis van het simulatiemodel en de algoritmes.

Praktische uitwerking vraagstelling

De performance van het simulatiemodel en de algoritmes worden voor dit artikel gepresenteerd in de vorm van de evaluatie van de laatste anderhalve maand van het jaar 2015. In de referenties [1, 3 en 4] wordt een verdere vergelijking gegeven op meer gedetailleerde criteria.

De algoritmes zijn getraind op data uit het jaar 2016; dit in verband

met beschikbaarheid van data van het elektriciteitsverbruik. Bij werkelijke toepassing van het concept uit Figuur 1 vindt dit natuurlijk omgekeerd plaats, maar het belangrijkste punt is dat de dataset waarop getest wordt niet is gebruikt voor het trainen van de algoritmes. Bij het testen van machine learning algoritmes is het van belang te trainen op een (onafhankelijke) dataset. Dat is in deze evaluatie het geval.

Een verschil tussen de algoritmes en het simulatiemodel is dat het simulatiemodel gebruikmaakt van een statisch

gemiddeld gebruikersprofiel dat afgeleid is uit het elektraverbruik over een periode van drie maanden (half november 2015 - half februari 2016). De algoritmes maken gebruik van het werkelijk gemeten elektraverbruik op dagbasis. Het invoeren van het dagelijkse elektraverbruik in het simulatiemodel was praktisch gezien een brug te ver voor de gehanteerde software (Vabi Elements 3.2).


Resultaten en discussie

Figuur 5 geeft een vergelijking tussen de metingen en de evaluatie van de energievraag ('predicted') door respectievelijk het neurale netwerk, het gradient boosting algoritme en het fysische simulatiemodel. Het neurale netwerk en het gradient boosting algoritme komen daarbij als beste uit de bus en geven onderling vergelijkbare resultaten. Het neurale netwerk presteert net iets beter en geeft een afwijking over de hele periode van slechts 0,3%. Dit betreft het verschil tussen het totaal van 'predicted' en het totaal van 'actual' over de periode van anderhalve maand. De individuele 'plussen' en 'minnen' van de voorspelling middelen elkaar uit. Het fysisch model geeft in deze periode over het algemeen een onderschatting waardoor de totale afwijking tussen de metingen en berekeningen uitkomt op 27%. Dat is aanzienlijk slechter.

Oorzaken van het minder presteren van het fysische model zijn onder meer de volgende.

- Het gebruik van statische patronen per dag voor het gebouwgebruik (gemiddelde van drie maanden).
- Het vereenvoudigen van de regelstrategie en bedrijfstijden van de verschillende subsystemen in de modellering. Er is in de casus sprake van een afgiftesysteem met vloerverwarming en vloerkoeling. Per vertrek worden de vloervelden aangestuurd door middel van een ruimtethermostaat. Het gebruik van de ruimtethermostaat wordt in het model uitgemiddeld over het gebouw. Wat bedrijfstijden betreft is er in de software een koppeling tussen de bedrijfstijd van de luchtbehandelingskast en de vloervelden. In werkelijkheid ligt dat iets gecompliceerder.

Op het totaal van het jaar 2015 geeft het fysisch model een afwijking van 18%, vergelijkbaar met eerder gemelde prestaties van het fysisch model op jaarbasis (15% afwijking) [1].



Figuur 5: Resultaten neurale netwerk, gradient boosting algoritme en fysisch model, warmtevraag op 24-uursbasis

Internationaal onderzoek meldt ook de relevantie van de modellering van het gebouwgebruik en de complexiteit van het modelleren van regelstrategieën. Tevens wordt er in ander onderzoek ook een nauwkeuriger resultaat behaald met een neurale netwerk in vergelijking met een fysisch model (EnergyPlus) [8].

Een kanttekening bij het gebruik van getrainde algoritmes is dat eventueel faalgedrag wordt meegetraind. Waarschijnlijk is dat hier ook het geval. Een deel van de afwijking van het fysisch model zit ook in de weekendperiode, een verschijnsel dat hoogstwaarschijnlijk samenhangt met minder optimale instellingen van setpoints [1,2].

Bij inzet van getrainde algoritmes is een koppeling met andere monitoringsgegevens van de installatie van belang in verband met mogelijk faalgedrag. Dat is hier niet verder uitgewerkt. Voor prestatiecontracten ontbreekt bij algoritmes ook de relatie met de afgesproken prestaties in het ontwerpproces. Voor het signaleren van trendmatige afwijkingen zoals geschetst in Figuur 1 zijn algoritmes echter het meest kansrijk.

Naast de nauwkeurigheid van de evaluatie van de energievraag speelt er ook nog een procesmatig aspect. Het implementeren van getrainde algoritmes in monitoringsystemen is eenvoudiger in vergelijking met het steeds opnieuw kalibreren van fysieke modellen en die vervolgens softwarematig koppelen aan monitoringssoftware.

Samenvattende conclusies

Getrainde algoritmes geven betere resultaten en zijn sneller operationeel te maken voor het bewaken van de energiestaat. Het nadeel is dat eventueel faalgedrag wordt meegetraind. Combinatie met andere monitorings-technieken is daarom essentieel. Het is daarbij bovendien belangrijk de inzet van algoritmes te combineren met zogenoemde initial commissioning waarbij de kwaliteit van de bemeting wordt gecontroleerd en de meest basale fouten in het functioneren van de installatie worden gecorrigeerd. Fysische simulatiemodellen blijven van groot

belang en bieden een veel meer onafhankelijke referentie, ook ten opzichte van wat er in het ontwerptraject als prestatie vooraf is afgesproken.

Dankwoord

De auteurs danken de andere coaches en co-readers van Rotterdam School of Management voor hun adviezen tijdens de uitvoering van het masteronderzoek (dr. Koen Dittrich, dr. Yashar Ghiassi-Farrokhfal, prof. Wolfgang Ketter). Het onderzoek naar fysieke modellen is mede uitgevoerd binnen het TKI-project Treco-office (www.treco-office.nl)

Succes en vervolgonderzoek

Dit artikel laat het succes zien van het evalueren van de energievraag op basis van getrainde algoritmes. Big data, kunstmatige intelligentie en machine learning zijn technieken waarvan ook de installatietechniek de vruchten kan plukken. Het zijn ook technieken met toenemende aandacht, zie bijvoorbeeld TVVL einddaglesing THE (big) DATA POTENTIAL.

In dit artikel hebben wij concrete resultaten laten zien. Wat DWA betreft is dit nog maar het begin van een veel bredere ontwikkeling. Begin 2018 zijn er twee studenten van Rotterdam School of Management gestart met een vervolgonderzoek. Verder heeft DWA een concept ontwikkeld om luchtbehandelingskasten te monitoren met behulp van getrainde algoritmes. In 2018 is daarmee een pilot uitgevoerd waarmee het concept in de praktijk wordt getest. De ontwikkelagenda richt zich op meerdere niveaus van toepassing (gebouw, portfolio, gebiedsniveau).

Referenties

1. Huijbregts, Z. & Wisse, K. (2017). Energieprestaties garanderen: hoe moeilijk is dat? VV+, juni 2017
2. Huijbregts, Z. & Wisse, K. (2017). Energiekosten garanderen in prestatiecontracten VV+, juli 2017.
3. Mariniak, J. (2017) Predicting Heating and Cooling Energy Demand in Buildings: A Gradient Boosting Approach. Master thesis Rotterdam School of Management, Erasmus University Rotterdam.
4. Horsten, D. (2017) A heating and cooling load benchmark model for a Dutch office building using an ANN approach. Master thesis Rotterdam School of Management, Erasmus University Rotterdam.
5. Zie bijvoorbeeld www.mindergas.nl.
6. Visier, J.E. (ed.). IEA-annex 40. Commissioning tools for improved energy performance, Results of IEA ECBCS ANNEX 40.
7. ISSO-publicatie 32 'Uitgangspunten temperatuursimulatieberekeningen' (2011).
8. D. Coakley, P. Raftery, and M. Keane, "A review of methods to match building energy simulation models to measured data," *Renew. Sustain. Energy Rev.*, vol. 37, pp. 123 - 141, 2014.