

Auteur

ir. Cristina Jurado Lopez, Energiespecialist, Deerns Nederland.
Co-auteurs: ir. Paul Stoelinga, Senior Consultant Energie, Deerns Nederland.
Prof.dr.ir. Laure C.M. Itard, Building Energy Epidemiology, TU Delft.

Eenvoudige voorspellende algoritmes om wijken klaar te maken voor 'slimme verwarming'

De transitie van het huidige, op fossiele brandstoffen gebaseerde energiesysteem naar een toekomstig systeem gebaseerd op hernieuwbare energie leidt tot onbalans in het energienetwerk. Een van de belangrijkste technologische schakels die ontbreekt in de energietransitie is de beschikbaarheid van eenvoudig in te voeren, slimme algoritmes, waarmee het traditionele elektriciteitsnetwerk op een kosteneffectieve manier in balans kan worden gehouden. Deze algoritmes moeten de verschillende soorten energiebronnen in de gebouwde omgeving (elektriciteit, verwarming en koeling) voorspellen en coördineren op wijk- en gebouwniveau. Dit onderzoek presenteert een eenvoudig, flexibel en snel algoritme, op basis van data, voor het voorspellen van de verwarmingsvraag. De eenvoud, nauwkeurigheid en fysische betekenis van de voorgestelde modellen maken het mogelijk het zelflerende vermogen van het model (machine learning) te automatiseren. Naast het voorspellen van de thermische vraag op wijk- en gebouwniveau, kunnen ze tevens worden ingezet voor predictieve regeling, voor het voorspellen van storingen en voor parametrische analyse.

Slimme stadsverwarming voor optimale integratie van duurzame bronnen

De gebouwde omgeving verbruikt meer dan 40% van de gebruikte energie in de wereld en draagt bij tot 30% aan de broeikasgasemissies [1]. Het verwarmen van de huishoudens in Europa is goed voor 79% van het totale energieverbruik en 84% van die verwarming wordt nog steeds gegenereerd uit fossiele brandstof [2]. Het verduurzamen van de warmtevraag in de gebouwde omgeving is van groot belang voor het bereiken van de vereiste energiedoelstellingen. Door de huidige manier van verwarmen in Nederland 'slim' te maken kan de CO₂-uitstoot door warmtegebruik snel verminderd worden, terwijl het ook effectief kan bijdragen aan het in balans houden van het elektriciteitsnetwerk [3]. Dit wordt bereikt door het fluctuerende aanbod af te stemmen op

de vraag en het elektrische systeem te integreren met het verwarmingsnetwerk (zie Figuur 1). Deze synergie tussen de verschillende energienetwerken vraagt om het gebruik van slimme regelingen aangestuurd door slimme algoritmes.

Nomenclatuur	
Symbolen	
C_i	Parameter coëfficiënt [-]
i	Sub index voor elke coëfficiënt van de parameter [-]
Q_h	Thermische energievraag per uur [W]
Q_{nte}	Interne warmtewinst [W]
Q_{sol}	Zonewarmtewinst [W]
Q_{env}	Warmteflux door de gebouwschil [W]
Q_{gr}	Warmteflux door begane grond [W]
Q_{vent}	Warmteflux door ventilatie [W]
Q_{inf}	Warmteflux door infiltratie [W]
$Q_{\text{th mass}}$	Warmte opgebouwd in de interne thermische massa [W]
T_{ground}	Oppervlaktetemperatuur aan de grond (buiten het gebouw) [°C]
T_{indoor}	Interne luchttemperatuur (vanuit het gebouw naar de AHU) [°C]
T_{outdoor}	Externe luchttemperatuur [°C]
$T_{\text{out AHU}}$	Uitlaatluchttemperatuur van de luchtbehandelingskast (Air Handling Unit - AHU) in het gebouw [°C]
$T_{\text{indoor surfaces}}$	Interne oppervlaktetemperatuur van oppervlakken met de meest beïnvloedende thermische massa [°C]
t	Bovenste index voor variabelen die in realtime gebruikt worden.
$t\text{-}n$	Bovenste index voor variabelen die 'n' uren voor realtime variabelen worden ingezet.
V_{wind}	Windsnelheid [m/s]

Eenvoudige, flexibele en nauwkeurige voorspellende algoritmes om gebouwen en wijken gereed te maken voor 'slim verwarmen'

De vereiste slimme algoritmes moeten eenvoudig, snel en flexibel genoeg zijn om de toekomstige hernieuwbare energiebronnen te laten integreren in het energiesysteem of met gebouw- en systeemrenovaties om te laten gaan. De huidige voorspellende algoritmes zijn fysica-gebaseerde (gebaseerd op de fysica) of datagestuurd (gebaseerd op statistiek) [5]–[9]. De op fysica gebaseerde algoritmes hebben heel veel inputparameters nodig, die in de praktijk moeilijk nauwkeurig in te schatten zijn. Op data

gebaseerde algoritmes zijn eenvoudiger en sneller dan fysica-gebaseerde algoritmes, maar missen fysische betekenis waardoor ze minder flexibel zijn voor toekomstige veranderingen. Dit onderzoek richt zich op de ontwikkeling en invoering van simpele, snelle en flexibele data-gebaseerde algoritmes (ook wel modellen genoemd) met fysische betekenis, voor de predictieve beheersing van de verwarmingsvraag in gebouwen.

Casestudy

Deze studie is ontwikkeld in het kader van het Innovation Programme for Intelligent Networks - IPIN in samenwerking met TU Delft en Deerns. IPIN wil het traditionele verwarmingsnetwerk van de TU Delft transformeren in een koolstofarm verwarmingsnetwerk door de introductie van lage temperatuur en (fluctuerende) thermische hernieuwbare bronnen (aardwarmte, afval-warmterecuperatie en toekomstige warmtepompenintegratie). Om dit doel op een betaalbare manier te bereiken was het volgende vereist:

1. Coördinatie tussen de gedecentraliseerde warmtebronnen en de warmtevraag vanuit het gebouw;
2. Verlaging van de aanvoertemperatuur (van 90 tot 65 °C).

Om dit te bereiken, ontwikkelde en implementeerde IPIN een op fysica gebaseerd, voorspellend controlesysteem dat de aanvoertemperatuur op campus- en gebouwniveau dynamisch aanpaste. Het fysica-gebaseerde algoritme vertoonde op grote schaal implementatiecomplexiteiten (zoals eerder uitgelegd). Het op data gebaseerde, voorspellende model dat in deze studie is ontwikkeld, pakt de problemen aan die zich voordoen bij het op fysica gebaseerde voorspellende controlesysteem. Het op data gebaseerde, voorspellende model transformeert traditionele Building Management Systemen (BMS) in een Smart BMS.

Figuur 1 toont de integratie en coördinatie van het elektriciteits- en verwarmingsnetwerk in de context van deze casestudy (gebouwen van TU Delft). In blauw zijn de drie bestudeerde TU Delft-gebouwen weergegeven: (1) 3mE (Faculteit Werktuigbouwkunde, Maritieme Techniek en Materiaalkunde), (2) IO (Industrieel Ontwerp) in (3) TBM (Techniek, Bestuur en Management).

Het onderzoek maakt gebruik van geëmuleerde en gemeten data van verschillende gebouwtypologieën. Deze studie ontwikkelt de volgende drie verschillende modellenvarianties:

- Model 1: Theoretisch model afhankelijk van 2 parameters. Dit model is gebaseerd op een geëmuleerde dataset op basis van de drie onderzochte gebouwen van de TU Delft (3ME, IO, TPM).
- Model 2: Theoretisch model richting implementatie in praktijk. Dit model is gebaseerd op een geëmuleerde dataset op basis van de drie onderzochte gebouwen van de TU Delft. De in het model geïntroduceerde parameters zijn beperkt tot de bestaande gemeten parameters.
- Model 3: Model geïmplementeerd in de praktijk (aanpassing en validatie). Dit model is gebaseerd op een werkelijke dataset. De parameters zijn aangepast aan de specifieke buitenomstandigheden van het gebouw.



Wiskundige methode


De wiskundige methode, die in deze studie is gebruikt, is een multivariabele lineaire regressie. De eenvoud van deze methode zorgt voor een eenvoudig eindmodel. De functionele vorm van deze aanpak is uitgedrukt in vergelijking 1 [4].

$$Q_h = \text{constant} + \sum_{i=1}^n C_i \cdot X_i \quad (1)$$

In deze vergelijking is Q_h de warmtevraag van het gebouw per uur; C zijn de overeenkomstige regressiecoëfficiënt van de afhankelijke variabele (gebruiksspecifieke kenmerken van gebouw en systemen); X is de afhankelijke parameter (zonnestraling, buitentemperatuur, warmtewinst, bezettingsgraad, enz.); en i de index van afhankelijke variabelen die voor het model zijn geselecteerd.

Figuur 1: Representatie van een slim energienetwerk bestaande uit een elektriciteitsnetwerk en een netwerk voor warmte. (campus TU Delft).





Figuur 2: Flowdiagram van de zoekprocedure en de gebruikte statistische criteria voor de selectie van predictorvariabelen [4].

Statistische validatie

Ieder ontwikkeld model is statistisch gevalideerd om de significantie van de gebruikte parameters te analyseren van het model te vermijden. Figuur 2 geeft een samenvatting van de zoekprocedure en de gebruikte criteria voor de juiste selectie van de predictorvariabelen [4].

Definities van een aantal modellen en vergelijkingen

In dit artikel worden de termen modellen en vergelijkingen gebruikt met een verschillende betekenis. Elk model is gebouwd met verschillende afhankelijke parameters (X: zonnestraling, bezetting, enz.). Daarnaast laat elk model verschillende karakteristieke vergelijkingen zien met verschillende regressiecoëfficiënten (C: gebruiksspecifieke bouw- en systeemkenmerken). Dit komt omdat gebouwen, systeemkenmerken of operationele posities de regressiecoëfficiënten beïnvloeden. Daarom heeft ieder gebouw en ieder bedrijfsgebruik een kenmerkende vergelijking voor ieder model. Deze vergelijking wordt verkregen door het model te kalibreren met de overeenkomstige dataset.



De eenvoud van de kalibratieprocedure maakt het mogelijk het proces te automatiseren en de vergelijking opnieuw aan te passen aan de mogelijk veranderende interne of externe condities. De onderzochte gebouwen hebben drie verschillende bedrijfsgebruiken: (A) werkdagen tijdens openingstijd, (B) weekends tijdens openingstijd, (C) sluitingstijd. De variabelen kunnen eenvoudig worden aangepast voor gebouwen die worden

beïnvloed door andere interne factoren, zoals renovatie aan gebouw of installaties of externe factoren zoals het hitte eiland effect, externe schaduwen of nieuwe energiebronnen. Dit maakt het model heel flexibel voor veranderingen. Dit wordt aangetoond in model 3.

Modelontwikkeling en de selectie van parameters

De selectie van variabelen is gebaseerd op de fysische principes van een thermische balans in een gebouw (zie Figuur 3). De warmtevraag van een gebouw hangt af van de hoeveelheid warmte die wordt overgedragen door de gebouwschil, en door de warmte die wordt geproduceerd en verzameld in het gebouw.

Om een fysisch betekenisvol model te maken is de selectie van parameters gebaseerd op de thermische energiebalans van een gebouw. De warmtestromen kunnen worden onderverdeeld in 6 hoofdcategorieën: interne warmtewinst (Q_{inte}), zonnewarmtewinst (Q_{sol}), verlies/winst door de gebouwschil ($Q_{gr} + Q_{env}$), ventilatie (Q_{vent}), infiltraties (Q_{infl}), en de warmte die verzameld wordt in de interne thermische massa (Q_{thmass}). De thermische massa verzamelt de warmte opgenomen uit zonnestraling, interne warmtewinst en de warmte in verschillende ruimtes. Voor geïsoleerde gebouwen kan worden aangenomen dat deze warmteflux alleen wordt overgedragen aan het binnenklimaat via het totale oppervlak van de interne thermische massa. De beschreven thermische energiebalans wordt uitgedrukt door vergelijking 2.



Figuur 3: Weergave van de warmtefluxen van de thermische balans van een gebouw.

$$Q_h = Q_{gr} + Q_{env} + Q_{inf} + Q_{vent} + Q_{thmass} + Q_{sol} + Q_{inte} \quad (2)$$

Deze vergelijking is gedeeltelijk uitgedrukt als een functie van de temperatuurverschillen die overeenkomen met iedere warmteflux zoals uitgedrukt in vergelijking 3.

$$Q_h = constant + C_a(T_{ground} - T_{indoor}) + C_b(T_{outdoor} - T_{indoor}) + C_c V_{wind} + C_d(T_{outAHU} - T_{indoor}) + C_e(T_{indoorsurfaces} - T_{indoor}) + C_f Q_{sol} + C_g Q_{inte} \quad (3)$$

Vergelijking 3 kan worden getransformeerd naar onafhankelijke temperaturen volgens vergelijking 4.

$$Q_h = constant + C_1(T_{outdoor}) + C_2(T_{indoor}) + C_3(V_{wind}) + C_4(T_{ground}) + C_5(T_{outAHU}) + C_6(T_{indoorsurfaces}) + C_7 Q_{sol} + C_8 Q_{inte} \quad (4)$$

De relatie aangeduid in vergelijking 4 (gedefinieerd door weergegevens en meetbare temperaturen) is gebruikt als basis voor het uiteindelijke model. C_i zijn de coëfficiënten behorend bij iedere parameter, die nu verschilt van de parameters aangegeven in vergelijking 3. Ze zijn om deze reden aangegeven met een verschillende index. De coëfficiënten van de variabelen komen overeen met de gebouw- en systeemkenmerken en worden verkregen door het model te gebruiken met historische gegevens op gebouwniveau. Zo beperkt het model de vraag naar gemeten data tot enkele meetbare parameters en laat daarmee alle parameters die gerelateerd zijn aan de gebouw- en systeemkenmerken achterwege (deze zijn in de meeste gevallen onbekend). Daarbij moet wel worden opgemerkt dat parameters die gerelateerd zijn aan gebouw- en systeemkenmerken als input uit de vergelijking zijn gehouden, maar hun invloed wordt wel meegenomen in de coëfficiënten van de kenmerkende vergelijking. Dit betekent dat ieder gebouw zijn eigen specifieke vergelijking heeft voor ieder bedrijfsgebruik. Bovendien kan de vergelijking eenvoudig opnieuw geijkt worden (aanpassing van de coëfficiënten) als externe of interne kenmerken veranderen, zoals een verbetering van de isolatiewaarde, veranderingen aan de installatie of andere energiebronnen.

Resultaten

Het algemene model als beschreven in vergelijking 4 is aangepast naar verschillende modellen met verschillende onafhankelijke variabelen. De eindmodellen die resulteren uit dit onderzoek zijn:

Model 1: Theoretisch model afhankelijk van 2 parameters

Vergelijking 5 toont de algemene vergelijking van model 1 voor de drie gebouwen van TU Delft (IO, 3mE en TPM). Model 1 toont aan dat met slechts 2 parameters (buitenluchttemperatuur en interne oppervlaktetemperatuur) de warmtevraag voorspeld kan worden met een nauwkeurigheid vallend tussen 96 – 99% ten opzichte van de geëmuleerde dataset. Dit komt omdat de interne oppervlaktetemperatuur zich draagt

als het thermisch geheugen van het gebouw en weerspiegelt gemakkelijk te meten parameters (zoals bezettingsgraad), moeilijk te meten parameters (zoals manipulatie van radiators of het aanzetten van een open haard) en niet-lineaire relaties zoals de thermische dynamiek van de thermisch massa.

$$Q_h \left[\frac{W}{m^3} \right] = constant + C_1(T_{outdoor}^t) + C_2(T_{indoorsurfaces}^t) \quad (5)$$

De grote nauwkeurigheid van dit model maakt deze vergelijking geschikt om in de praktijk te worden geïmplementeerd. De temperatuur van interne oppervlakken is echter een parameter die in de casestudy meestal niet beschikbaar is. Als de variabele uit de vergelijking wordt gehouden, neemt het *passende profiel* voor de drie gebouwen af tot 79,42% voor IO, 52,9% voor 3mE en 63,52% voor TPM ten opzichte van de geëmuleerde dataset. Daarom zou de interne oppervlaktetemperatuur moeten worden vervangen door bekende variabelen om nauwkeurig genoeg te zijn voor mogelijke toepassingen. Om die reden is model 2 ontwikkeld.

Model 2: Theoretisch model richting implementatie in de praktijk

Om een model te bouwen dat kan worden toegepast met werkelijke data in plaats van met geëmuleerde data is de keuze in parameters beperkt tot die data die het meest gemeten worden. In model 2 (vergelijking 6) is de interne oppervlaktetemperatuur vervangen door de interne warmtewinst van 1 uur eerder en de zonnestraling van 3 uur eerder. De uren eerder zijn genomen vanwege de dynamische thermische reactie van het gebouw. De zonnestraling is ook nog eens 2 uur vroeger dan de interne warmtewinst, omdat de dataset gebruik maakt van de horizontale zonnestraling (in plaats van de zonnestraling op het vlak van de ramen in de gevel).

$$Q_h \left[\frac{W}{m^3} \right] = constant + C_1(T_{outdoor}^t) + C_2(T_{indoor}^{t-1}) + C_3(V_{wind}^t) + C_4(T_{ground}^t) + C_5(T_{outAHU}^t) + C_6(Q_{inte}^{t-1}) + C_7(Q_{sol}^{t-3}) + C_8(Q_{sol}^t) + C_9(Q_{inte}^t) \quad (6)$$

Model 2 laat een *passend profiel* zien van tussen 73 – 90% voor de drie universiteitsgebouwen. Figuur 4 geeft het voorspellend potentieel van model 2 voor de 3 geanalyseerde gebouwen. Het linker gedeelte geeft het *passende profiel* van het model weer op het gebied van de historische data (de geëmuleerde

dataset die gebruikt is om het model te bouwen) en het rechter gedeelte (voorspelde data) toont de voorspellende waarde (validatie) van het model.

In alle gevallen neemt de discrepantie op maandagen toe. Dit komt omdat het gebouw tijdens de weekenden verder afkoelt dan tijdens weekdagen, waardoor de invloed van de interne oppervlaktetemperatuur groter is. Dat kan worden verbeterd door een correctiefactor te introduceren of door 2 verschillende regressievergelijkingen te maken: (1) met alleen maandagen (2) met de weekdagen van dinsdag tot en met vrijdag.

Model 3: Model geïmplementeerd in de praktijk (aanpassing en validatie)

Dit model is ontwikkeld om de grote potentiële flexibiliteit van het model aan te tonen en dient als validatie van de methode door een actuele dataset van een kantoorgebouw te gebruiken. Model 3 is weergegeven in vergelijking 7. Model 2 is gebruikt als basis voor de ontwikkeling van model 3, maar de onafhankelijke parameters zijn aangepast zodat zij matchen met de soort (beschikbare) gemeten data in het gebouw en met specifieke beïnvloedende parameters. De interne warmtewinst (mensen + verlichting + machines) is vervangen door de gemeten bezettingsgraad en er zijn twee buitentemperaturen in het model opgenomen: (1) voorspeld door het KNMI en (2) gemeten temperatuur op het dak van het gebouw. Dit omdat de omgeving van het dak een hogere temperatuur heeft dan de gevels, veelal door donkere dakbedekking.


$$Q_h \left[\frac{W}{m^3} \right] = Constant + C_1(T_{outdoorKNMI}^t) + C_2(T_{outdoorroof}^t) + C_3(Q_{sol}^{t-3}) + C_4(Occupancy^t) + C_5(Occupancy^{t-3}) + C_6(T_{indoorair}^t) \quad (7)$$

Dit model laat zien dat minstens 77% van de werkelijke warmtevraag kan worden gerelateerd aan de buitentemperatuur, de zonnewinst, de binnenlucht, en de gerelateerde aanwezigheidsvariabelen waaronder interne warmtewinst. Deze nauwkeurigheid is gemeten ten opzichte van de werkelijke (gemeten) dataset.

Conclusies

De conclusie van dit onderzoek is dat de voorgestelde lineaire regressiemodellen veelbelovend presteren om een snel, flexibel en gemakkelijk te implementeren algoritme te worden voor het voorspellen van de verwarmingsvraag in gebouwen. Het resultaat is een kosteneffectievere methode dan bestaande modellen op basis van fysica of wetmatigheden. Figuur 5 vergelijkt het ontwikkelde model ('Developed model') versus een fysica gebaseerd model ('Law-driven model') en een op data gebaseerd model ('Data-driven model'). Dit onderzoek bewijst dat een slimme selectie van parameters in combinatie met een eenvoudig algoritme het volgende bewerkstelligt:

- *Vermindering van het aantal parameters dat moet worden gemeten.* Alle ontwikkelde modellen beperken de vraag naar vereiste gemeten waarden tot een paar gemakkelijk te meten parameters en weergegevens. Model 1 laat zien dat de interne oppervlaktetemperatuur een belangrijke parameter is om te meten. De interne oppervlaktetemperatuur gedraagt zich als het thermisch geheugen van het gebouw en weerspiegelt gemakke-



Figuur 4: Fitting profile van het model voor de dataset Oktober-December 2015 voor de drie universiteitsgebouwen

lijk te meten parameters, moeilijk te meten parameters en niet-lineaire relaties zoals het thermisch gedrag van het gebouw.

- *Minimalisatie van de hoeveelheid te verzamelen data en een toename van de nauwkeurigheid van de voorspelling.* Het eerste deel van het onderzoek laat zien dat geëmulleerde data van het vorige seizoen (~2 maanden) in staat zijn de volgende maand te voorspellen met een nauwkeurigheid in een range van 96-99% in het eerste model en 73-91% in het tweede model.
- *Eenvoudige transformatie van traditionele gebouwbeheersystemen (GBS) naar slimme energieregelaars.* Dit eenvoudige en snelle lineaire algoritme kan worden ondersteund door iedere GBS, waardoor de complexiteit van de implementatie beperkt is en tijd wordt bespaard.
- *Eenvoudige implementatie in bestaande gebouwen en op grote schaal (van campus naar nationaal niveau).* De modelflexibiliteit in combinatie met het relatief kleine aantal te monitoren data maakt het model eenvoudig aanpasbaar aan de beschikbare dataset en nieuwe fysische parameters (renovaties, nieuwe energiesystemen of veranderende buitencondities) die van invloed zijn. Model 3 bewijst dat het model eenvoudig kan worden aangepast aan werkelijke situaties. Het aangepaste model, meermaalen gebruikt met reële metingen, had een nauwkeurigheid van 77%.

Om het ontwikkelde model in de praktijk toe te passen, wordt het volgende werk aanbevolen:

- *Testen van het model met een grotere dataset (inclusief voor- en naseizoen).* De gebruikte gegevenssets komen overeen met de koudste periode, wanneer alleen verwarming wordt gebruikt. Het wordt aanbevolen om het model te testen met een grotere gegevensset, inclusief maanden in de herfst en lente. Tijdens deze maanden zal de invloed van de oppervlaktetemperatuur binnenshuis toenemen als gevolg van een grotere invloed van zonnestraling en (gelijktijdig of alternatief) gebruik van koeling in het gebouw.
- *Testen van het model in gebouwen met grotere bedrijfs-schommelingen.* De gebouwen die in dit onderzoek zijn gebruikt, hebben relatief stabiele bedrijfsomstandigheden. Het wordt aanbevolen om het model te testen in gebouwen met grotere bedrijfsschommelingen, zoals woningen.

Deze kenmerken maken het mogelijk het zelflerend vermogen van het model te automatiseren en het te gebruiken voor het voorspellen van de vraag naar thermische energie op gebouwniveau of op grotere schaal, voor predictieve regeling, voor het voorspellen van storingen in de systemen en voor parametrische analyse.



Cristina Jurado Lopez,
Energiespecialist, Deerns Nederland

Figuur 5: Vergelijking van het ontwikkelde model (licht groen) versus een fysica-gebaseerd model (medium groen) en een data-gebaseerd model (donker groen).



 Law-Driven model	- >200 variables - Complex to detect relations	- Introduction errors (parameters estimation)	- Inventory & calibration - Programming interaction with other softwares	+ Physical meaning	- Complex to introduce new physical relations with 'unknowns'
 Data-Driven model	+ <10 variables - Large data set (>1 year)	- Introduction errors (no physical meaning)	+ Can be automatized + introduced in BMS	- No physical meaning	- Difficult to introduce physical meaningful parameters
 Developed model	+ 2-6 variables - Small data set (<2 months) + Simple to detect relations	+ No introduction errors (all 'unknowns' accounted)	+ Can be automatized + introduced in BMS	+ Physical meaning	- Easy to introduce any physical meaningful parameters

Referenties

1. "UN Environment Programme - Environment for Development : Buildings and Climate Change: Summary for Decision Makers [.] 2009
2. "Heating and cooling - Energy - European Commission," Energy. [Online]. Beschikbaar: /energy/en/topics/energy-efficiency/heating-and-cooling. [Geopend: 1 februari 2017].
3. H. Lund et al., "4th Generation District Heating (4GDH): Integrating smart thermal grids into future sustainable energy systems," Energy, vol. 68, pp. 1-11, april 2014.
4. J. P. M. de Sá, Applied Statistics Using SPSS, STATISTICA, MATLAB en R. Springer Science & Business Media, 2007.
5. E. H. Borgstein, R. Lamberts, en J. L. M. Hensen, "Evaluating energy performance in non-domestic buildings: A review," Energy and Buildings, vol. 128, pp. 734-755, sept. 2016.
6. D. Coakley, P. Raftery, en M. Keane, "A review of methods to match building energy simulation models to measured data," Renewable and Sustainable Energy Reviews, vol. 37, pp. 123-141, sept. 2014.
7. Z. Li, Y. Han, en P. Xu, "Methods for benchmarking building energy consumption against its past or intended performance: An overview," Applied Energy, vol. 124, pp. 325-334, juli 2014.
8. T. A. Reddy en K. K. Andersen, "An Evaluation of Classical Steady-State Off-Line Linear Parameter Estimation Methods Applied to Chiller Performance Data," HVAC&R Research, vol. 8, no. 1, pp. 101-124, jan. 2002.
9. H. Zhao en F. Magoulès, "A review on the prediction of building energy consumption," Renewable and Sustainable Energy Reviews, vol. 16, no. 6, pp. 3586-3592, aug. 2012.