

Auteurs

dr. ir. S. (Shalika) Walker. ing. J.W. (Jan-Willem) Dubbeldam. P. (Petros) Zimianitis (MSc., Eng.D.)
ir. J. A.J. (Joep) van der Velden (Kropman B.V., Nijmegen)

De toekomst van gebouwbeheersystemen: van datagedreven inzichten naar predictieve regeling

De energietransitie transformeert gebouwen van louter energiegebruikers tot actieve deelnemers aan het energienet. Deze studie, geïnspireerd op de resultaten van het industrieel onderzoeksproject Model Predictive Control for Energy Flexibility (MoPreCEF), introduceert een open-structuur gebouwbeheersysteem (GBS) dat gebruikmaakt van verschillende databronnen, energieverbruik kan voorspellen en dynamisch optimaliseert. Door voorspellende regel- en flexibiliteitsstrategieën te combineren, draagt het bij aan netstabiliteit, versnelde decarbonisatie en kostenefficiëntie.

Gebouwen vervullen een steeds actievere rol binnen het Europese energienet, wanneer hun energieverbruik dynamisch kan worden aangepast. Deze ontwikkeling vereist een nieuwe generatie Gebouwbeheersystemen (GBS). Traditionele GBS-oplossingen zijn veelal gesloten, leverancier-specifiek en reactief, en missen de datagedreven intelligentie, openheid en interoperabiliteit die noodzakelijk zijn om te communiceren met diverse databronnen en effectief te reageren op signalen vanuit het energienet.

Het Nederlandse onderzoeksproject Model Predictive Control for Energy Flexibility (MoPreCEF) speelt in op deze uitdaging door de ontwikkeling van een open-gestructureerd GBS dat in staat is verschillende databronnen te integreren, energieverbruik te voorspellen en predictieve optimalisatie toe te passen. Deze benadering vergroot de energie-flexibiliteit van gebouwen en ondersteunt een slimmer, toekomstbestendig en responsief gebouwbeheer.

Dit artikel beschrijft de kernprincipes van de open-structuurarchitectuur en presenteert de resultaten van pilotimplementaties. Tevens worden de implicaties besproken voor het toekomstige ontwerp van GBS-systemen en de bijdrage van de Europese bouwensector aan data-gedreven energie-flexibiliteit.

Technisch kader

De nieuwe generatie gebouwbeheer vereist intelligentere regelsystemen die het energieverbruik kunnen voorspellen en proactief kunnen reageren op veranderende omstandigheden. Door zelf energie op te wekken en op te slaan, en zich aan te passen aan perioden met beperkte externe toevoer, kunnen gebouwen efficiënter opereren en waardevolle flexibiliteit bieden aan het energienet. Studies tonen aan dat dergelijke intelligente regelstrategieën het totale energieverbruik van gebouwen met meer dan 20% kunnen verminderen en de piekvraag naar elektriciteit tot wel >50% kunnen terugdringen [1], [2].

Om dit te realiseren, moeten regelsystemen niet alleen realtime gegevens integreren van traditionele gebouwgebonden klimaat- en energiesystemen, maar ook externe databronnen benutten. Deze omvatten weersvoorspellingen, bezettingspatronen en historische prestatiegegevens van gebouwinstallaties, zonne-energiesystemen, elektrische voertuigen en lokale opslagsystemen. Geavanceerde data-analyse en op machine learning (ML) gebaseerde predictieve regeling kunnen historisch opgeslagen gegevens uit deze databronnen interpreteren om het energieverbruik te voorspellen (ML algoritmen zoals: XGBoost, Random Forest, MLP (ANN)), systeemreacties te optimaliseren en de interactie met het net te coördineren. Deze integrale benadering maakt nauwkeurigere besluitvorming mogelijk en verbetert de algehele systeembetrouwbaarheid.

Open-structuur GBS

Toekomstige gebouwbeheersystemen (GBS) zullen in toenemende mate een centrale rol vervullen als knooppunt voor verschillende datastromen binnen een gebouw [3]. Om deze rol te kunnen vervullen, moet een GBS over de volgende basisfunctionaliteiten beschikken:

- Het verbinden van diverse realtime databronnen.
- Het snel en flexibel verbinden van verschillende historische databronnen.
- Het opslaan van historische datapunten en -structuren.
- Het uitvoeren van berekeningen met realtime en historische data.
- Het presenteren van realtime en historische data en bijbehorende Key Performance Indicators (KPI's).
- Het beschikbaar stellen van realtime en historische data via open standaarden (API).

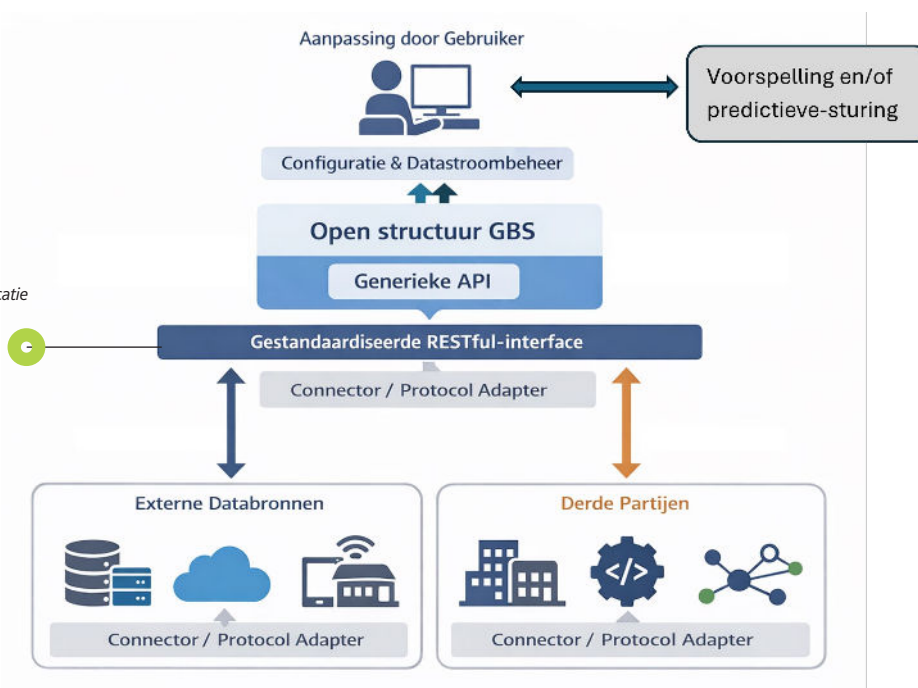
Een Application Programming Interface (API) is een gestandaardiseerde methode waarmee verschillende softwaresystemen gegevens kunnen uitwisselen en met elkaar kunnen communiceren. Binnen een GBS maakt een open API het mogelijk om data te delen met externe systemen, informatie te ontvangen van bijvoorbeeld weerservices of energienetten, en integraties te ondersteunen met voorspellende regelalgoritmen of externe analysetools.

Daarnaast:

- Het uitvoeren van datagedreven voorspellingen van gebouwgedrag.
- Het ondersteunen van besluitvormingsalgoritmen voor datagedreven, predictieve regeling (bijv. Model Predictive Control (MPC)).
- Het hosten van predictieve regelsystemen die realtime setpoint-optimalisaties kunnen uitvoeren in gekoppelde systemen (databronnen).

Deze uitgebreide functionaliteiten stellen GBS-platforms in staat om verder te gaan dan passieve monitoring, richting actief energiemanagement, interoperabiliteit tussen leveranciers en naadloze integratie met slimme energienetten. Deze evolutie maakt het mogelijk dat gebouwen functioneren als intelligente, zelf optimaliserende systemen binnen het bredere energie-ecosysteem. Om een open gestructureerd systeem te realiseren, is het belangrijk dat de inkomende en uitgaande datastromen door de gebruiker kunnen worden aangepast. Om een GBS "open" te maken, moet een generieke API worden ontwikkeld die gegevensuitwisseling met externe bronnen en derde partijen mogelijk maakt. Deze verbindingen moeten worden gestandaardiseerd via een RESTful-interface, die aan de backend is gekoppeld aan de specifieke API of het protocol van de betreffende databron (zie Figuur 1).

Figuur 1: Data communicatie weergave.



Een RESTful-interface is een communicatiestijl voor webservices die gebruikmaakt van standaard HTTP-methoden (zoals GET, POST, PUT en DELETE) om gegevens op een gestructureerde en uniforme manier tussen verschillende systemen uit te wisselen.

Prognose en predictieve-sturing

Deze studie beschrijft hoe Kropman deze functionaliteiten heeft uitgebreid binnen hun data- en gebouwbeheersysteem InsiteSuite [3]. Om een predictieve regeling mogelijk te maken, vereist een modern GBS nieuwe functionaliteiten. Een van deze functionaliteiten is een predictiemodule, ontworpen om machine learning te integreren voor modeltraining en voorspellingen. Deze machine learning-voorspellingen kunnen patronen in het energieverbruik herkennen en op systeemreacties van het gebouw anticiperen, waardoor proactieve aanpassingen en geoptimaliseerde prestaties mogelijk zijn. Door zowel realtime als historische gegevens van sensoren, klimaatsystemen, energieopslag en hernieuwbare energiebronnen continu te analyseren, kan de module zijn voorspellingen verfijnen en de nauwkeurigheid van toekomstige prognoses verbeteren. Aangezien het trainen van deze modellen meer rekenkracht en geheugen vereist dan onder normale omstandigheden beschikbaar is, dient de module te worden ondersteund door specifiek servers voor de uitvoering van deze taken. De module moet via API's kunnen communiceren met versleutelde authenticatie over een beveiligde verbinding, waardoor veilige integratie met andere gebouwssystemen en externe databronnen mogelijk is voor gecoördineerde, predictieve regeling. De geavanceerde predictiemodule voor gebouwbeheersystemen (GBS) is ontworpen om via een API over een beveiligde verbinding met elke gebruiker te communiceren. Na authenticatie hebben gebruikers toegang tot verschillende functionaliteiten, zoals:

- **Projecten**

Gebruikers kunnen projecten aanmaken voor verschillende toepassingen en doeleinden. Binnen deze projecten kunnen zij bestanden en modellen opslaan, wijzigen en verwijderen.

- **Algoritmen**

De module biedt een bibliotheek met machine learning-algoritmen die beschikbaar zijn voor modeltraining. Gebruikers kunnen ook de hyperparameters van algoritmen bekijken en aanpassen.

- **Modellen**

Gebruikers kunnen modellen trainen met hun eigen data en deze opslaan binnen projectmappen. Ze kunnen de prestaties van modellen evalueren, indien nodig opnieuw trainen en de getrainde modellen gebruiken voor voorspellingen. Deze voorspellingen kunnen worden gebruikt om regelsignalen of andere operationele beslissingen binnen het GBS te sturen.

- **Databestanden**

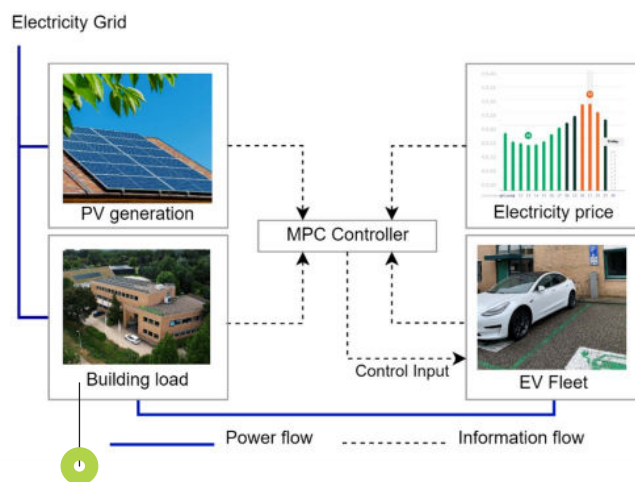
De data ten behoeve van training en voorspelling worden aangeleverd conform het vereiste standaardformaat.

De module volgt de processtappen van algemeen geaccepteerde en gebruikte machine learning bibliotheken, waardoor deze intuïtief en gemakkelijk is in gebruik. Bovendien kan een speciale clientbibliotheek (bijv. voor Python) de communicatie met de module vereenvoudigen, waardoor een naadloze integratie in bestaande workflows en projecten mogelijk is.

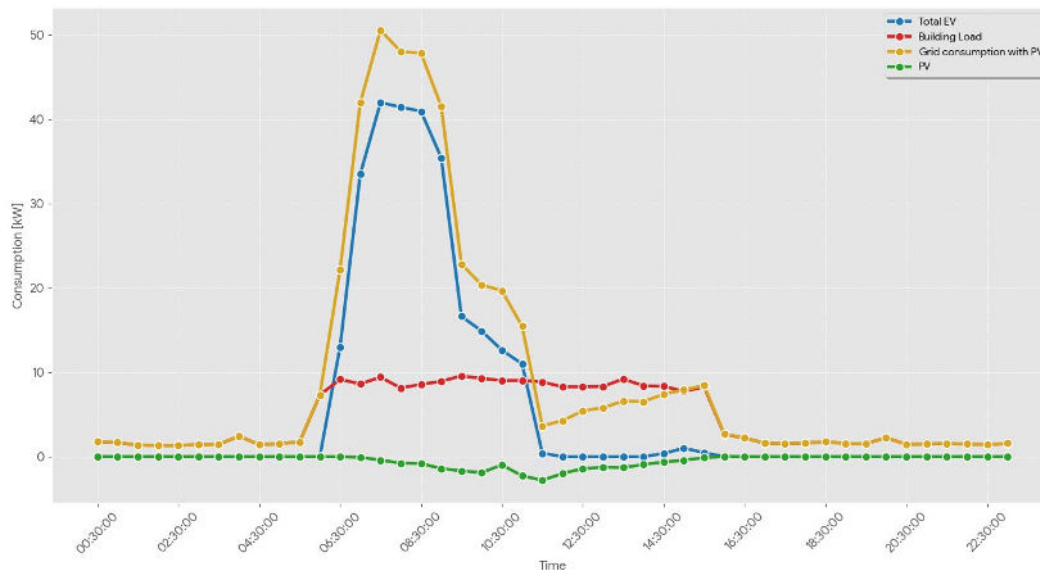
Implementatie

In deze sectie wordt een voorbeeld van een modelpredictieve regelaar voor slim opladen van elektrische voertuigen (EV) gepresenteerd, binnen het eerder beschreven kader voor machine learning-voorspelling en -regeling [3].

De implementatie vond plaats in een gemonitord kantoorgebouw in Breda, Nederland, met 4 laadpunten (3-fase/16A/11kW), PV-panelen met een totale capaciteit van 16,9 kW, een luchtbehandelingsunit (AHU), een koelinstallatie en netaansluiting. Het gemiddelde gebouwvermogen bedraagt 14 kW. De werking van de slimme regelaar is weergegeven in Figuur 2. De predictieve regelaar gebruikt historische en realtime gegevens van het gebouw en de laadpunten om EV-laadschema's te optimaliseren, het gebruik van onsite PV-energie te maximaliseren, en piekvraag op het net te verminderen, waarmee de praktische voordelen van machine learning-integratie in gebouwenergiemanagement duidelijk worden.



Figuur 2: Modelpredictieve regelaar representatie.



Figuur 3: Belasting-/verbruiksprofielen voor een geselecteerde dag (21-02-2024) – geen slimme regelaar gebruikt.

Momenteel ervaart het gebouw ochtendpieken in het vermogen die bijna de capaciteit van de gecontracteerde transformator bereiken, zoals te zien is in Figuur 3. Deze pieken worden voornamelijk veroorzaakt door het gelijktijdig functioneren van HVAC-systemen, kantoorapparatuur en het opladen van meerdere elektrische voertuigen. Deze hoge pieken ontstaan wanneer de PV-productie nog niet beschikbaar is, en tegen de tijd dat de PV-opwekking start, zijn de EV's vrijwel volledig opgeladen. Deze situatie is verre van ideaal, aangezien dergelijke hoge vraagperiodes kunnen leiden tot hogere energiekosten, mogelijk hoge piekbelasting van de elektrische infrastructuur en een lagere algehele efficiëntie.

De slimme regelaar gebruikt gegevens van het gebouw, EV-gebruikers en externe diensten, zoals elektriciteitsprijvoorspellingen, om energiestromen te optimaliseren en kosten te minimaliseren, terwijl operationele efficiëntie behouden blijven. De regelaar analyseert continu realtime- en historische gegevens, past laadschema's dynamisch aan en coördineert met de onsite PV-productie, waardoor het energieverbruik kostenefficiënt wordt en bijdraagt aan de duurzaamheids- en operationele doelstellingen van het gebouw.

De Model Predictive Controller (MPC), zoals weergegeven in Figuur 4, bestaat uit meerdere onderling verbonden submodules die ook onafhankelijk van elkaar kunnen functioneren. Deze submodules zijn:

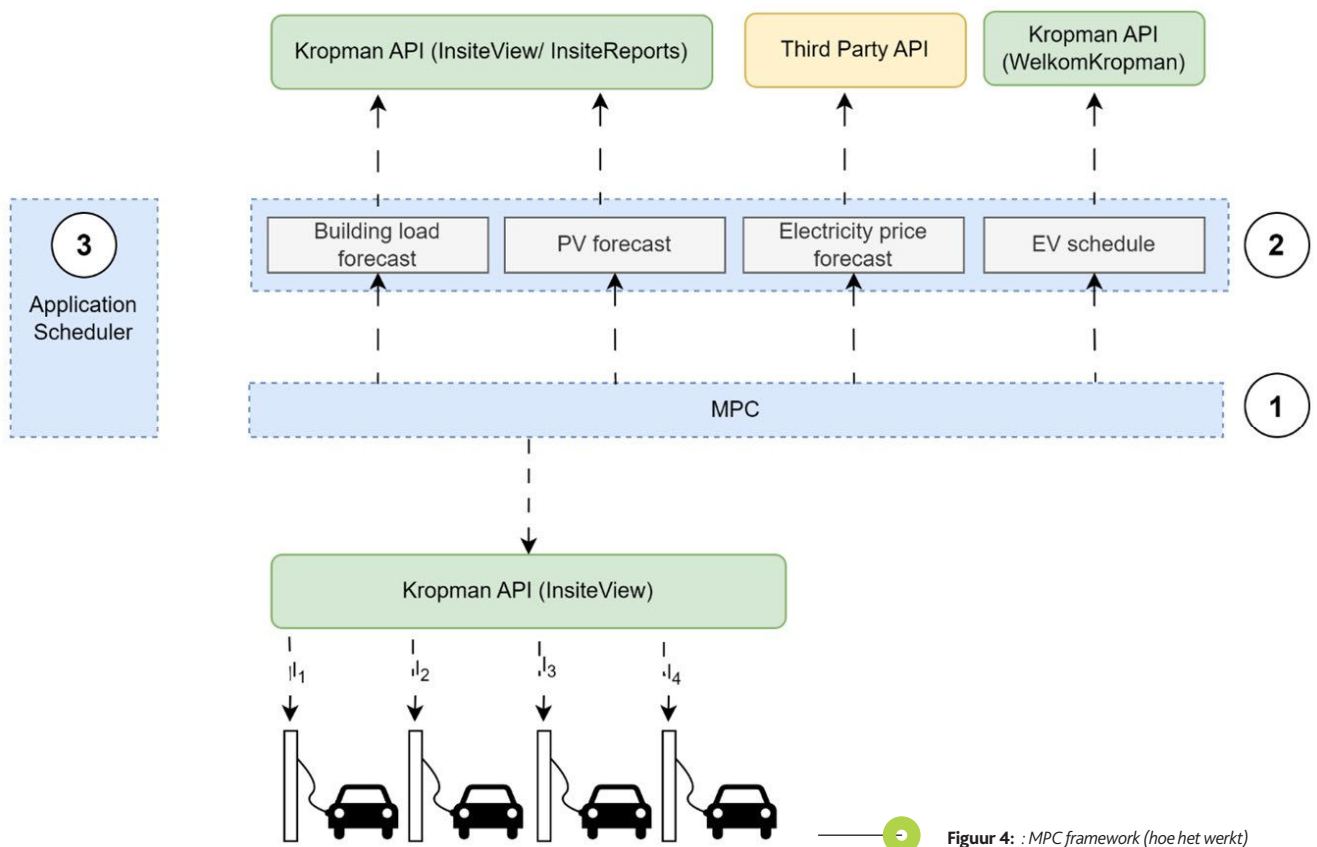
1. **De Data Preparation Service** – verantwoordelijk voor het verzamelen, opschonen en formatteren van gegevens van gebouwssystemen, EV-laadpunten, PV-installaties en externe bronnen.

2. **De Optimization Service** – voert predictieve berekeningen uit en bepaalt optimale regelsignalen op basis van voorspellingen, randvoorwaarden en doelstellingen zoals kostenminimalisatie of energie-efficiëntie.
3. **De Scheduler** – voert de geoptimaliseerde regelacties in realtime uit, coördineert met gebouwssystemen en externe signalen en waarborgt tegelijkertijd operationele veiligheid en gebruikerscomfort.

Deze submodules werken samen binnen het GBS om data, voorspellingen en controles naadloos te integreren.

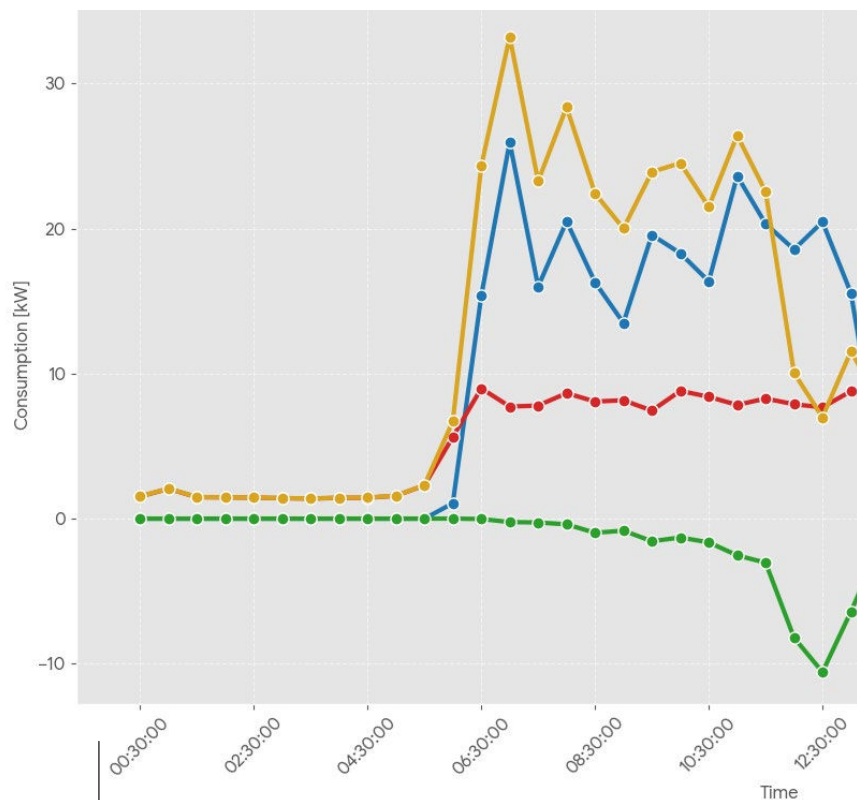
In elke optimalisatiecyclus start de scheduler een reeks taken. Aan het begin van de dag wordt de elektriciteitsprijvoorspelling opgehaald bij de energieleverancier. Vervolgens worden de volgende taken elke 15 minuten uitgevoerd: de PV-voorspelling wordt bijgewerkt en het gebouwverbruik voorspeld door een machine learning model dat is getraind op historische en realtime GBS gegevens. EV-gebruikers leveren daarbij belangrijke informatie, zoals de huidige laadstatus en verwachte vertrektijd van hun voertuig, die via de GBS-interface aan de MPC wordt doorgegeven.

Al deze gegevens — PV-opwekking, gebouwvraag, energieprijzen en gebruikersschema's — worden verwerkt in de optimalisatiemodule. De MPC berekent hier de optimale laadregelsignalen en stroomprofielen, waarmee piekvraag, kosten en zelfverbruik worden gebalanceerd. Deze regelsignalen worden via het GBS naar de laadpunten gestuurd, waardoor een dynamische, data-gedreven regeling ontstaat die realtime reageert op wijzigende omstandigheden.



Figuur 4: MPC framework (hoe het werkt)

De regelaar verlaagt het piekvermogen van het opladen van EV's en daarmee het totale piekvermogen van het gebouw gemiddeld met 28% ten opzichte van een ongecontroleerd laadsysteem. Deze vermindering levert niet alleen economische voordelen door lagere maximale vraagkosten, maar maakt ook de uitbreiding van EV-laadinfrastructuur binnen de bestaande transformatorcapaciteit mogelijk. Afhankelijk van de energietariefstructuur kan dit leiden tot gemiddelde kostenbesparingen van 24% tot 30% op piekvraag. Belangrijk is dat deze resultaten zijn behaald zonder concessies te doen aan de laadbehoeften of het gebruikerstevredenheid van EV-rijders, terwijl bovendien meer operationele flexibiliteit wordt geboden en de belasting op het lokale elektriciteitsnet wordt verminderd. Zie Figuur 3 en Figuur 5: twee relatief goed vergelijkbare dagen met een vergelijkbare totale EV-laadenergie per dag. De vergelijking laat de piekreductie zien met en zonder regeling.



Figuur 5: Belasting-/verbruikprofielen voor een geselecteerde dag (21-02-2024) – geen slimme regelaar gebruikt.

Conclusie over GBS uitbereiding

Zoals blijkt uit de voorbeeldstudie maakt het uitbreiden van het GBS met data communicatie een predictieve in plaats van reactieve regeling mogelijk, waardoor gebouwen op hun energievraag kunnen anticiperen en de prestaties kunnen optimaliseren. Effectief gebruik hangt af van het integreren van diverse gegevens, zoals sensoren, voorspellingen, prijzen en bezetting, via gestandaardiseerde API's en open protocollen in het GBS.

Data-gedreven GBS-functionaliteiten, gecombineerd met optimalisatie algoritmen, tonen een groot potentieel voor het vergroten van energieflexibiliteit, het ondersteunen van vraagrespons en het faciliteren van slimme netintegratie. Deze aanpak vermindert het energieverbruik, verlaagt piekbelastingen en beperkt netcongestie, terwijl tegelijkertijd de systeem flexibiliteit, schaalbaarheid en interoperabiliteit verbeteren. Bovendien kan een data-gestuurd GBS continu leren en zich aanpassen aan veranderende gebruikspatronen, omgevingsomstandigheden en gebruikersgedrag, wat zowel kostenbesparingen als lange termijn duurzaamheidsdoelen binnen gebouwen bevordert. Ondanks de voordelen blijven er verschillende uitdagingen bestaan bij het uitbreiden van GBS voor data- en AI-toepassingen:

- Aanvullende reken- en opslagcapaciteit – Het trainen en uitvoeren van ML-modellen vraagt extra verwerkingskracht en opslag ten opzichte van traditionele GBS-functionaliteiten, hoewel dit doorgaans binnen gangbare IT-infrastructuren voor gebouwbeheer kan worden ondergebracht.
- Datakwaliteit en beschikbaarheid – De prestaties van ML zijn sterk afhankelijk van accurate, goed gestructureerde en voldoende data van gebouwssystemen en externe bronnen.
- Interoperabiliteit – Integratie met diverse protocollen en legacy-systemen kan complex zijn.
- Databeveiliging en privacy – Het uitwisselen en opslaan van (operationele) data vereist passende maatregelen op het gebied van cybersecurity, toegangsbeheer en naleving van geldende wet- en regelgeving.
- Vereiste deskundig personeel – Het ontwikkelen, implementeren en onderhouden van oplossingen vereist ervaren datawetenschappers, ingenieurs en domeindeskundigen, die niet altijd beschikbaar zijn.
- Gebruikersadoptie – Facility managers en operators moeten zich aanpassen aan nieuwe tools en processen, hetgeen training en verandermanagement vereist.

Het overwinnen van deze uitdagingen vereist modulair systeemontwerp, voldoende rekenkracht, intuïtieve interfaces en robuuste data governance strategieën om bredere adoptie in de industrie te ondersteunen. Datagedreven toepassingen kunnen worden opgeschaald over meerdere subsystemen, zoals verwarming, ventilatie en airconditioning (HVAC), verlichting, energieopslag en het opladen van elektrische voertuigen [4], [5]. Dit kan de operationele efficiëntie, energieflexibiliteit en kosteneffectiviteit binnen modern facility management verhogen.

Dankwoord

Dit project wordt gefinancierd door Topsector Energie Gebouwde Omgeving (TSE-GO):

TSEGO23003 <https://buildinflexergy.nl/moprecef>

Referenties

1. A. Afram and F. Janabi-Sharifi, "Theory and applications of HVAC control systems – A review of model predictive control (MPC)," *Build. Environ.*, vol. 72, pp. 343–355, Feb. 2014, doi: 10.1016/j.buildenv.2013.11.016.
2. L. Chamari, S. Walker, E. Petrova, and P. Pauwels, "Energy Demand Optimisation in Pv- and Ev-Integrated Buildings: A Supervisory Controller Based on Mpc," 2025. doi: 10.2139/ssrn.5238682.
3. Kropman B.V., "InsiteSuite SCADA and Energy Management System," <https://insitesuite.nl/>.
4. W. Tang, Y. Li, S. Walker, and T. Keviczky, "Model Predictive Control Design for Unlocking the Energy Flexibility of Heat Pump and Thermal Energy Storage Systems," in 2024 IEEE Conference on Control Technology and Applications (CCTA), IEEE, Aug. 2024, pp. 433–439. doi: 10.1109/CCTA60707.2024.10666588.
5. B. A. L. M. Hermans, S. Walker, J. H. A. Ludlage, and L. Özkan, "Model predictive control of vehicle charging stations in grid-connected microgrids: An implementation study," *Appl. Energy*, vol. 368, p. 123210, Aug. 2024, doi: 10.1016/j.apenergy.2024.123210.

