

Auteurs Dr.ir. R.P. (Rick) Kramer¹, Dr.ir. S. (Shalika) Walker²

1) Technische Universiteit Eindhoven, Department of the Built Environment

2) Kropman B.V.

Automatische Fout Detectie en Diagnose binnen bereik?

Naar schatting zijn tenminste 80% van de gebouwen 'besmet' door fouten in gebouwgebonden installaties. Die fouten zorgen voor suboptimale prestaties met soms wel 25% energieverlies. Ook zorgen die fouten vaak voor comfortklachten van gebruikers. Digitalisering en AI-gebaseerde tools in gebouwen kunnen helpen bij het vroegtijdig identificeren van die fouten binnen installaties. Dit artikel informeert u over de ontwikkelingen binnen het Brains4Buildings project ten behoeve van Automatische Fout Detectie en Diagnose (AFDD).

Waarom gebruiken gebouwen meer energie dan verwacht? De meeste gebouwen gebruiken in de operationele fase meer energie dan verwacht. De energierekening is hoger dan de rekenmodellen hadden voorspeld tijdens de ontwerpfase. Daar zijn meerdere redenen voor. Het gebruikersgedrag heeft grote invloed door het gebruik van thermostaten, te openen ramen, en verlichting. Er is echter nog een belangrijke reden: veel energie voor klimaatbeheersing gaat verloren door fouten in de gebouwgebonden installaties. Schattingen lopen op tot 25% van het totale energiegebruik voor HVAC-systemen. Naar schatting zijn 80% van de gebouwen 'besmet' met fouten (later in dit artikel wordt duidelijk waarom we deze medische term gebruiken). Naast een hoog energiegebruik zorgen fouten vaak ook voor een suboptimaal binnenklimaat. Dat vertaalt zich naar bijvoorbeeld thermisch discomfort van gebruikers.

Er zijn verschillende typen fouten te onderscheiden: (i) defecte actuatoren; (ii) afwijkende sensormetingen; (iii) incorrecte (regel)instellingen. Ontwerpfouten vallen buiten de scope van dit artikel. Die fouten leiden tot symptomen, zoals een te lage

inblaastemperatuur, of een te hoge ruimtetemperatuur wat dus uiteindelijk kan leiden tot ontevreden gebouwgebruikers.

Het opsporen van de symptomen en de onderliggende oorzaken, ofwel de fouten, is van essentieel belang voor een goed presterend gebouw. Want naast onzuinige en oncomfortabele gebouwen zorgen fouten in gebouwgebonden installaties ook dat het moeilijker is om nieuwe Smart Technologies toe te passen, zoals slimme regelingen voor meer energieflexibiliteit.

De rol van AFDD in gebouwinstallaties

Het is logisch dat er nieuwe technieken nodig zijn om symptomen automatisch te kunnen opsporen en de onderliggende fouten te diagnosticeren. Digitalisering voor foutdetectie en -diagnose in gebouwen houdt in dat geavanceerde technologieën, zoals sensornetwerken, AI en data-analyse, worden geïntegreerd om systemen in real-time te monitoren. Door gegevens te verzamelen van verschillende gebouwssystemen, zoals van HVAC, verlichting en elektrische netwerken, kunnen deze tools afwijkingen of inefficiënties vroegtijdig identificeren. AI-algoritmen kunnen patronen analyseren, potentiële storingen voorspellen en corrigerende acties voorstellen voordat problemen escaleren. Dat verlaagt onderhoudskosten en verbetert energie-efficiëntie. Deze proactieve benadering verlengt de levensduur van gebouwinstallaties te verlengt en zorgt voor een comfortabel en gezond binnenmilieu voor de gebruikers.

Het proces van AFDD verloopt in twee stappen:

Symptoomdetectie

Eerst worden afwijkingen opgespoord en bepaald of het en symptomen is. Symptoomdetectie is het

gebruik van voorspellingen van sensorwaarden door een machine learningmodel om deze te vergelijken met meetwaarden. Vervolgens wordt met statische technieken bepaald of een afwijking een symptoom is. Op het moment van schrijven vindt een studie plaats om de prestaties van verschillende machine learningmodellen met elkaar te vergelijken, waarbij met name gekeken wordt naar XGBoost (een decision tree model), Neural Networks, en Support Vector Machines.


Foutdiagnose

Na symptoomdetectie, volgt de tweede stap van foutdiagnose. Dat is het opsporen van de onderliggende fouten, die een gevonden symptoom veroorzaakt. Hiervoor wordt een probabilistische techniek gebruikt op basis van bayesiaanse netwerken. Figuur 1 laat zien hoe fouten kunnen leiden tot symptomen. Er is een bepaalde kans dat deze fouten voorkomen in het systeem, de zogeheten prior probability (PP). Als een fout daadwerkelijk optreedt, is er een bepaalde kans dat een specifiek symptoom zich voordoet, de zogeheten conditional probability (CP). Het proces van diagnose verloopt in omgekeerde richting door de gedetecteerde symptomen te linken aan de fouten en de kans te berekenen welke fout de onderliggende oorzaak kan zijn. De uitkomst is

dus een probabiteit op basis van kansberekening. Deze werkwijze is analoog aan de werkwijze van een arts: bij de symptomen 'hoest', 'koorts' en 'smaakverlies' is de kans het grootst dat 'COVID' de oorzaak (fout) is. Op deze manier kan een gerichte test ingezet worden om te bepalen of COVID daadwerkelijk de onderliggende boosdoener is. Analoog hieraan kan een service engineer gerichter te werk gaan om de onderliggende oorzaak op te sporen en te verhelpen in een luchtbehandelingskast of andere gebouwinstallatie.

Data-efficiëntie voor schaalbaarheid en generaliseerbaarheid

De afgelopen jaren hebben we een enorme opkomst meegemaakt van data-gedreven technieken, recentelijk vaak gelabeld als AI. Inmiddels hebben we ook een beter begrip van de uitdagingen van puur data-gedreven technieken, zoals de enorme hoeveelheid (gelabelde) data die nodig is om een model goed te kunnen trainen. Vaak is data niet beschikbaar over een lange periode voor alle benodigde datapunten. Ook is data vaak niet gelabeld, missen er datapunten (tijdelijk), of is de onderlinge samenhang van datapunten niet duidelijk. Daardoor neemt het verzamelen, organiseren en voorbereiden van data veel tijd in beslag. In het Brains4Buildings project richten we ons daarom strategisch op data-efficiënte technieken die schaalbaar zijn en generaliseerbaar. Dat doen we op zo:



Figuur 1: Een bayesiaans netwerk legt de probabilistische relaties vast tussen symptomen (S) en de onderliggende fouten (Fout). Daarbij worden de prior probabilities (PP) en conditional probabilities (CP) gebruikt om te achterhalen welke fouten waarschijnlijk geleid hebben tot de gedetecteerde symptomen.

1. Specifiek focussen op de belangrijkste fouten

Niet alle fouten zijn even belangrijk. Sommige fouten komen meer voor dan andere en de impact van de fout kan ook verschillen. Daarom hebben we een studie uitgevoerd naar welke fouten de grootste impact hebben op het energiegebruik [1]. Hierbij hebben we ons in deze eerste studie gefocust op de luchtbehandelingskast. De impact is gedefinieerd als de Frequentie dat een fout voorkomt X Energiegebruiktoename door de fout.

Voor het bepalen van de frequentie van fouten hebben we een analyse uitgevoerd van de onderhoudslogboeken in samenwerking met SPIE op basis van text-mining technieken.

De energiegebruikstoename is bepaald in samenwerking met Kropman voor hun kantoor in Breda door de fouten te simuleren in EnergyPlus.

De hoofduitkomst is dat de belangrijkste fouten voorkomen in de volgende componenten: (i) ventilator; (ii) warmteterugwinwiel, (iii) stuurklep verwarmingsbatterij, (iv) stuurklep koelbatterij. De resultaten zijn inmiddels gepubliceerd in het tijdschrift Energy & Buildings [1].

2. Zoveel mogelijk modelstructuren en parameters op kennis baseren

Gebruik bestaande expertise van systemen bij het ontwikkelen van modellen. Dat doen we door de


modelstructuur, input-output-relaties, en prior probabilities en conditional probabilities zoveel mogelijk te baseren op kennis, en vervolgens de overige parameters te trainen op data. Het combineren van kennis en datagedreven technieken is essentieel voor effectieve en efficiënte AFDD ontwikkelingen. De TU/e heeft interviews gehouden met experts van SPIE en Kropman om zoveel mogelijk kennis op te halen voor de ontwikkeling van een schaalbaar bayesiaans netwerk voor toepassing op luchtbehandelingskasten.

3. Modulaire AFDD applicaties ontwikkelen

Onderzoek duurt totaal vier jaar en ontwikkeling is nog niet afgerond. Daarom richten we ons nu uit strategisch oogpunt op modulaire oplossingen voor een optimale schaalbaarheid en beheersbaarheid. Zo heeft de TU Delft gewerkt aan de mogelijkheid om het bayesiaans netwerk op te bouwen uit standaard componenten op basis van een bibliotheek met een bayesiaans modellen per component.

4. Gebruikersfeedback integreren

Behaaglijkheid en thermisch comfort staan niet in de gebouwd data. Daarom hebben we een effectieve enquête-applicatie ontwikkeld, die toegespitst is op AFDD. Vragen richten zich vooral op het detecteren van onbehagen. Daarbij maken we gebruik maken van skip logic. Zo leggen we alleen de relevante vragen voor aan de gebruikers. Deze applicatie kan gekoppeld worden met data uit het gebouwbeheersysteem om AFDD effectief en efficiënt te verwerken.



Figuur 2: Roadmap voor een AFDD pilotproject.

Van theorie naar de praktijk

Foutdetectietools gebaseerd op machine learning, hebben toegang nodig tot hoogwaardige, real-time gegevens om effectief te zijn. Veel gebouwen missen echter de benodigde sensoren en infrastructuur voor gegevensverzameling, of de beschikbare gegevens zijn mogelijk onvolledig of onbetrouwbaar. Voor goede data zijn vaak extra gekalibreerde sensoren nodig in de gebouwinstallaties, met bewakingssystemen. Bij Kropman wordt de volgende roadmap gevolgd om AFDD-toepassingen uiteindelijk bij klanten te kunnen toepassen, zie Figuur 2.

AFDD van theorie naar praktijk brengen via een pilotproject heeft 9 stappen voor een succesvolle implementatie, test en schaalbaarheid.

1. Stel duidelijke doelstellingen

Bepaal doelen: Stel specifieke doelen voor het pilotproject. Bijvoorbeeld: test de effectiviteit van AFDD-tools bij het identificeren van HVAC-systeemfouten of het verbeteren van energie-efficiëntie.

Succesmetingen en KPI's: Bepaal hoe succes gemeten zal worden, zoals lagere uitvaltijd, onderhoudskosten of energieverbruik, en verbeteringen in de nauwkeurigheid van foutdetectie.

2. Kies een representatief gebouw en installatie

Selectie van pilotlocatie: Kies een gebouw of een deel van een gebouw met voldoende complexiteit en een mix van systemen (HVAC, verlichting, beveiliging, etc.), die profiteren van foutdetectie.

Begrijp de infrastructuur: Beoordeel of de bestaande gebouwinfrastructuur, benodigde sensoren, communicatienetwerken en digitale systemen de AFDD-tools ondersteunen.

3. Installeer benodigde sensoren en data-systemen

Upgrade infrastructuur: Installeer als het nodig is (extra) sensoren en gegevensverzamelingsystemen voor nauwkeurige, real-time gegevensverzameling. Bijvoorbeeld

sensoren voor temperatuur, luchtvochtigheid, luchtkwaliteit en energiegebruik. Het Kropman InsiteSuite SCADA-systeem zal worden gebruikt.

Kalibreer systemen: Kalibreer de sensoren en systemen voor nauwkeurige gegevens.

4. Train het team

Vaardigheden ontwikkelen: Train het gebouwbeheer- en onderhoudsteam in het gebruik van het AFDD-systeem, het interpreteren van gegevens en het effectief reageren op waarschuwingen.

Praktijkgerichte training: Bied praktische, hands-on training voor een soepele overgang van theorie naar praktijk, zoals het leren beheren en oplossen van de fouten die de AFDD-tool identificeert.

5. Voer het pilotproject uit door te monitoren en te testen

Monitoring en testen: Tijdens de pilot is het noodzakelijk gebleken de stappen te identificeren die nodig zijn om het systeem in de toekomst AFDD-ready te maken. Evalueer hoe goed de methoden fouten identificeren, systeemstoringen voorspellen en gebouwactiviteiten optimaliseren.


6. Analyseer de resultaten

Prestatie-evaluatie: Beoordeel de resultaten aan de hand van de vastgestelde doelen en succesmetingen (stap 1), zoals de nauwkeurigheid van foutdetectie, operationele verbeteringen, kostenbesparingen en klanttevredenheid.

Identificeer uitdagingen: Noteer eventuele uitdagingen die zich tijdens de pilot hebben voorgedaan (bijv. gegevens onnauwkeurigheden, systeemintegratieproblemen of gebrek aan responsiviteit van gebouwssystemen).

7. Verfijn en optimaliseer

Itereer op basis van feedback: Gebruik de inzichten uit de pilot om het AFDD-systeem te



Figuur 3: Monitoring van de luchtbehandelingskast in de pilot na installatie van de sensoren, inclusief alarmen om geïdentificeerde fouten aan te geven.

verfijnen en te optimaliseren. Pabijvoorbeeld AI-algoritmes aan, verplaats sensoren of stel de waarschuwingsdrempels bij.

Los hiaten op: Identificeer en los eventuele hiaten op in technologie, training van personeel of gegevensverzameling die de prestaties van de AFDD-tools kunnen belemmeren.

8. Schaal op

Breder implementeren: Schaal op bij een succesvolle pilot. Implementeer de geleerde lessen uit de pilot. Dat zorgt er voor dat de infrastructuur, training en AFDD-tools klaar zijn voor bredere implementatie.

Continue monitoring en verbetering: Blijf de prestaties van de AFDD-tools volgen, zelfs na de opschaling. Breng verbeteringen aan naarmate de technologie en gebouwssystemen evolueren.

9. Documenteer en deel de resultaten

Documenteer leerervaringen:

Documenteer de geleerde lessen tijdens de pilot. Zowel de successen als uitdagingen. Dat maakt toekomstige implementaties succesvoller.

Deel met stakeholders: Communiceer de resultaten met belangrijke belanghebbenden, waaronder gebouweigenaren, facilitair managers en IT-teams. Dat geeft draagvlak voor bredere adoptie.

Deze stappen geven een leidraad om de AFDD-technologie met succes van theoretische concepten naar de praktijk te brengen, en om zo de gebouwprestaties te optimaliseren, onderhoudskosten te verlagen en te zorgen voor een efficiënter en duurzamer operationeel beheer.

Uitdagingen

Er zijn verschillende redenen waarom AFDD-tools vandaag de dag niet direct kunnen worden geïntegreerd in gebouwinstallaties:

1. Veel gebouwen maken nog gebruik van verouderde infrastructuur, die niet is ontworpen om samen te werken met moderne digitale tools of AI-technologieën. Het integreren van deze systemen met nieuwe tools vereist vaak aanzienlijke upgrades of vervangingen, wat kostbaar en complex kan zijn.
2. Verschillende gebouwssystemen (HVAC, verlichting, beveiliging, etc.) gebruiken vaak incompatibele protocollen en standaarden. Dit gebrek aan interoperabiliteit maakt het moeilijk om verschillende systemen te verbinden en nieuwe tools effectief te integreren zonder gespecialiseerde interfaces of middleware.
3. Het implementeren van digitale tools en AI voor foutdetectie vereist aanzienlijke initiële investeringen in zowel technologie als training. Dit kan een belemmering zijn, vooral voor oudere gebouwen of organisaties met beperkte budgetten.
4. Naarmate meer apparaten en systemen met het internet zijn verbonden, neemt het risico op cyberaanvallen toe. Het beveiligen van deze digitale tools en het waarborgen van naleving van gegevensprivacyregulering voegt een extra laag complexiteit toe.

5. Gebouweigenaren en facilitair managers kunnen terughoudend zijn in het aannemen van nieuwe technologieën vanwege de waargenomen risico's, de noodzaak om personeel bij te scholen en de verstoring van bestaande werkprocessen.
6. In sommige regio's houden bouwvoorschriften en regelgeving mogelijk nog geen rekening met de integratie van digitale tools of AI. Dit kan het adoptieproces vertragen en juridische of compliance-hindernissen creëren.

Het overwinnen van deze uitdagingen vereist gecoördineerde inspanningen, investeringen in infrastructuur en technologische vooruitgangen, die naadloze integratie van AFDD-tools in diverse gebouwssystemen mogelijk maken. In het Brains4Buildings project werken we aan Automatische Fout Detectie en Diagnose technieken die zoveel mogelijk de effecten van de genoemde uitdagingen mitigeren door te focussen op schaalbaarheid en generaliseerbaarheid.

Dankwoord

De beschreven studie is onderdeel van het onderzoeksproject Brains4Buildings. Het project heeft subsidie ontvangen vanuit het RVO MOOI instrument onder projectnummer MOOI32004. Een bijzonder woord van dank gaat uit naar: prof.dr. Laure Itard en prof.em.ir. Wim Zeiler voor hun inzet bij de totstandkoming van het project.

Referenties

1. Gopalan, S., Rijs, A., Chitkara, S., Thamban, A., Kramer, R. Fault prioritisation for Air Handling units using fault modelling and actual fault occurrence data, Energy & Buildings, 319, Elsevier, 2024.