



**UHASSELT**

KNOWLEDGE IN ACTION

## Faculteit Bedrijfseconomische Wetenschappen

master handelsingenieur in de beleidsinformatica

### **Masterthesis**

***Detecteren van gedragsafwijkingen in een smart home omgeving***

**Evi Nulmans**

Scriptie ingediend tot het behalen van de graad van master handelsingenieur in de beleidsinformatica

### **PROMOTOR :**

Prof. dr. Benoit DEPAIRE



**UHASSELT**

KNOWLEDGE IN ACTION

[www.uhasselt.be](http://www.uhasselt.be)  
Universiteit Hasselt  
Campus Hasselt:  
Martelarenlaan 42 | 3500 Hasselt  
Campus Diepenbeek:  
Agoralaan Gebouw D | 3590 Diepenbeek

**2022**  
**2023**



# **Faculteit Bedrijfseconomische Wetenschappen**

master handelsingenieur in de beleidsinformatica

## ***Masterthesis***

### ***Detecteren van gedragsafwijkingen in een smart home omgeving***

#### **Evi Nulmans**

Scriptie ingediend tot het behalen van de graad van master handelsingenieur in de beleidsinformatica

#### **PROMOTOR :**

Prof. dr. Benoit DEPAIRE



# Detecteren van gedragsafwijkingen in een smart home omgeving

Evi Nulmans

Master handelsingenieur in de beleidsinformatica

Promotor: Prof. dr. Benoît Depaire

Universiteit Hasselt, Agoralaan gebouw D 3590 Diepenbeek

**Abstract.** Het detecteren van gedragsafwijkingen in smart homes kan een belangrijke bijdrage leveren aan de veiligheid, de gezondheid en het welzijn van bewoners. Het detecteren van afwijkend gedrag wordt ook wel anomaliedetectie genoemd. Tot op heden focuste anomaliedetectie zich voornamelijk op het detecteren van activiteiten met een ongebruikelijke duurtijd of activiteiten die worden overgeslagen. Echter is er weinig onderzoek verricht naar het detecteren van gedragsafwijkingen in de tijd. Nochtans is het van belang om ook deze afwijkingen op te sporen. De geringe onderzoeken die hieromtrent bestaan, maken gebruik van clustermethodes waarbij een activiteit pas als afwijkend wordt beschouwd wanneer deze niet past binnen de cluster en daarbovenop ook nog eens aanzienlijk langer duurt. Een nadeel hiervan is dat bepaalde afwijkingen niet worden opgemerkt, namelijk wanneer ze niet significant langer duren dan de normale activiteiten binnen de cluster of dicht bij de centroid gelegen zijn. Bijgevolg zullen we in deze masterproef een methode voorstellen die ook deze afwijkingen opspoorst. Om dit te verwezenlijken, zullen we twee neurale netwerken ontwerpen. Het ene neurale netwerk zal de volgende activiteit voorspellen, terwijl het andere het tijdstip voorspelt waarop de volgende activiteit plaatsvindt. De output van deze neurale netwerken wordt vervolgens gebruikt om het verwachte gedrag van de persoon gedurende een dag weer te geven. Dit kan bijgevolg worden vergeleken met het werkelijke gedrag dat de persoon vertoont. Met behulp van statistische methodes, meer specifiek t-testen de daarbij horende verwerpingsgebieden, zal dan worden achterhaald of er significante gedragsafwijkingen in de tijd plaatsvinden tussen het verwachte en werkelijke gedrag. Over het algemeen kunnen we concluderen dat de voorgestelde methode effectief is in het detecteren van gedragsafwijkingen in de tijd en daarbovenop betere prestaties levert dan de bestaande clustermethodes.

**Keywords:** smart home, neurale netwerk, gedrag, gedragsafwijking

## 1 Introductie

Slimme technologieën en Internet of Things hebben de groei van smart homes de afgelopen jaren sterk gestimuleerd. Smart homes zijn inmiddels een integraal onderdeel van de woningbouw geworden en bieden diverse voordelen, zoals verbeterde veiligheid, gemak, energie-efficiëntie en comfort. Vanwege hun groeiende populariteit en voordelen wordt verwacht dat smart homes in de toekomst een nog prominentere rol zullen spelen in onze maatschappij. Het is waarschijnlijk dat ze steeds meer worden geïntegreerd in onze dagelijkse routines en een onmisbaar onderdeel zullen worden van ons dagelijks leven. In de literatuur wordt een smart home gedefinieerd als een efficiënt beheersysteem voor woningen die statische apparaten kan omzetten in een bestuurbaar netwerk [26]. De eindgebruiker hoeft de interne werking van een smart home niet te begrijpen, maar kan op een interactieve en gebruiksvriendelijke manier de apparaten bedienen en real-time

informatie hierover raadplegen. Met deze informatie kan de gebruiker zijn levensstijl zodoende optimaliseren [40]. Aanvankelijk werden smart homes dan ook geconceptualiseerd en ontwikkeld om mensen met een fysieke en/of verstandelijke beperking te ondersteunen. Als gevolg hiervan spelen smart homes vandaag de dag een prominente rol in het faciliteren van zelfstandig wonen [8].

Smart homes zijn meer specifiek in staat hulp te bieden zonder dat ze de dagelijkse activiteiten van een persoon beperken of verstoren. Dit zorgt ervoor dat de persoon meer comfort, zelfstandigheid en welzijn ervaart [7]. Een technologie die dit mogelijk maakt is Ambient Assisted Living (AAL) [11]. AAL is meer specifiek een technologie dat als doel heeft mensen te helpen in hun dagdagelijks leven door te leren en te reageren op hun gedrag [6]. Door verschillende technologieën en sensoren in de leefwereld van een persoon te integreren, kan er gebruik worden gemaakt van AAL. Het monitoren van Activities of Daily Living (ADL's) is een belangrijk concept binnen AAL [11]. ADL's spelen namelijk een belangrijke rol in het beoordelen van het vermogen van een persoon om zelfstandig te leven [11]. Daarnaast helpen ze in het ontwerpen en implementeren van sensoren die enerzijds in staat zijn activiteiten van een persoon te volgen, maar anderzijds ook in staat zijn om ongebruikelijke activiteiten te detecteren [21]. Het is echter belangrijk om ADL's te monitoren met als doel afwijkend gedrag te detecteren, dit wordt ook wel anomaliedetectie genoemd. Het voordeel van anomaliedetectie is tweeledig, enerzijds voelt de bewoner zich veiliger en anderzijds verlaagt het de druk voor familieleden om de persoon zeer frequent te controleren [29]. Afwijkend gedrag kan namelijk wijzen op gezondheidsproblemen zoals dementie of op gevaarlijke incidenten zoals een val [21]. Wanneer er niet tijdig gehandeld wordt, kan dit aanzienlijke gevolgen hebben voor de persoon in kwestie [34].

Binnen smart homes focust anomaliedetectie zich voornamelijk op het detecteren van activiteiten met een ongebruikelijke duurtijd of activiteiten die worden overgeslagen [14][29]. Daarentegen is er in de literatuur tot op heden weinig onderzoek verricht omtrent het detecteren van afwijkend gedrag in de tijd. In essentie betekent dit dat er activiteiten gedecteerd worden die op een gegeven tijdstip niet worden verwacht. Echter kunnen ook deze afwijkingen wijzen op abnormaal en/of alarmerend gedrag [31]. Bijgevolg zal deze masterproef zich toespitsen op het detecteren van deze gedragsafwijkingen. Wanneer we namelijk op een gegeven tijdstip opmerkelijk gedrag waarnemen, kan dit een signaal zijn omtrent de gezondheid en het welzijn van de persoon. Door deze afwijkingen te detecteren en vervolgens de persoon te informeren, kunnen we zijn levenskwaliteit verbeteren [4]. Om dit te verwezenlijken zullen er twee neurale netwerken ontworpen worden. Het ene neurale netwerk zal in staat zijn om de volgende activiteit te voorspellen, daar waar het andere neurale netwerk het tijdstip van de volgende activiteit voorspelt. Vervolgens wordt de output van deze twee neurale netwerken gebruikt om de verwachte activiteiten met bijhorende tijdstippen van een dag weer te geven. Hierdoor verkrijgen we een overzicht van het verwachte gedrag van een persoon voor een bepaalde dag. Bijgevolg wordt dit verwachte gedrag vergeleken met het werkelijke gedrag dat de persoon vertoont. Om te bepalen of er significante verschillen optreden op bepaalde tijdstippen tussen het verwachte en werkelijke gedrag, zal er gebruik worden gemaakt van t-testen en de daarbij horende verwerpsgebieden. Om vervolgens te achterhalen of de voorgestelde methode beter presteert dan de bestaande clustermethodes, zullen we beide methodes uitvoeren op de test dataset en de resultaten met elkaar vergelijken.

De volgende sectie biedt een overzicht van gerelateerd onderzoek, met specifieke aandacht voor het voorspellen van activiteiten en het detecteren van gedragsafwijkingen. Bovendien zullen we

hier belangrijke concepten zoals routines, gedrag en activiteiten verder verduidelijken. Hierna wordt de voorgestelde methode en de methodologie van deze masterproef uiteengezet, gevolgd door de bespreking van de resultaten en de conclusie.

## 2 Gerelateerd onderzoek

### 2.1 Wat zijn routines, gedrag en activiteiten?

Routines, gedrag en activiteiten zijn drie nauw verwante concepten die te maken hebben met hoe we handelen en functioneren in de wereld om ons heen. Een routine wordt in de literatuur gedefinieerd als een reeks van activiteiten die frequent voorkomt op een bepaald tijdstip of binnen een bepaalde context [4][24]. Ze verwijzen naar de gewoontes en patronen die we ontwikkelen bij het uitvoeren van bepaalde activiteiten. Bovendien worden routines vaak geassocieerd met dagelijkse taken en worden ze vaak onbewust uitgevoerd [23][15]. Een activiteit verwijst daarentegen naar de handelingen die we ondernemen om een bepaald doel te bereiken of om een bepaalde taak uit te voeren. Activiteiten kunnen variëren van dagelijkse taken zoals koken en schoonmaken tot complexe taken zoals het oplossen van wiskundige problemen of het schrijven van een boek. Zoals hierboven reeds vermeld, bestaat een routine steeds uit een bepaalde reeks van activiteiten [31]. Het gedrag van een persoon verwijst daarentegen naar de verschillende acties en activiteiten die een persoon tijdens een typische dag uitvoert. Dit kan variëren afhankelijk van de persoon zijn levensstijl, dagelijkse taken, verantwoordelijkheden, werk, sociale activiteiten, hobby's en interesses. Veelvoorkomende gedragingen van een persoon doorheen de dag zijn: opstaan, douchen, eten, drinken, uitvoeren van werk- of schoolgerelateerde taken, ontspannen, uitvoeren van huishoudelijke taken, sporten enzovoort.

Kortom verwijst een routine naar een herhalende reeks activiteiten die een persoon gewoonlijk uitvoert op een bepaald tijdstip of in een bepaalde situatie. Het gedrag van een persoon omvat daarentegen alle activiteiten die een persoon gedurende een dag uitvoert. Routines vormen mee het gedrag van een persoon, al zijn er ook gedragingen die niet gestuurd worden door een bepaalde routine [4][23]. Binnen deze masterproef zullen we ons toespitsen op gedrag en de daarbij horende gedragsafwijkingen. Meer specifiek zullen we kijken of het werkelijke gedrag van een persoon op bepaalde tijdstippen overeenkomt met het gedrag dat we op deze tijdstippen zouden verwachten. Indien hiertussen een significant verschil optreedt, spreken we van een gedragsafwijking in de tijd.

### 2.2 Voorspellen van volgende activiteiten

Smart home data wordt onder andere gebruikt om gebruikersgedrag te voorspellen [39][35]. Hierdoor zijn we in staat vroegtijdig een waarschuwing te sturen naar de betrokkenen waardoor afwijkend of alarmerend gedrag tijdig bijgestuurd of zelfs voorkomen kan worden [10]. Een benadering die hierbij kan helpen is om de volgende activiteiten die een persoon zal uitvoeren te voorspellen. Het voorspellen van de volgende activiteit(en) wordt in de praktijk vooral toegepast op processen [16]. Het doel hiervan is om ongewenste uitkomsten vroegtijdig te identificeren [12].

Om de volgende activiteit van een proces te voorspellen, worden enerzijds traditionele machine learning methodes, zoals decision trees, en anderzijds deep learning methodes, zoals neurale netwerken, gebruikt. De laatste jaren gaat de voorkeur uit naar deep learning methodes aangezien deze consistent betere resultaten opleveren dan traditionele machine learning methodes [26][28]. In de literatuur worden voornamelijk volgende deep learning methodes gebruikt: Recurrent Neural Networks, Long Short-Term Memory Networks, Convolutional Neural Networks, Generative Adversarial Networks en (Stacked) Autoencoders [37][28][16][1]. Welke methode exact gebruikt wordt, hangt af van de kenmerken van de beschikbare gegevens omtrent het proces [28]. Desondanks er verschillende methodes beschikbaar zijn, maken ze allen gebruik van een eventlog als input. Een eventlog bevat informatie over welke activiteiten hebben plaatsgevonden, wanneer ze hebben plaatsgevonden en in welke volgorde [28][37]. Om het model verder te verfijnen, wordt er ook meer gedetailleerde informatie aan toegevoegd, zoals de duurtijden van voorgaande activiteiten, wie het proces of een activiteit uitvoert, de plaats van uitvoering, het moment van de dag/week en tijdstippen van voorgaande activiteiten. Deze informatie is cruciaal om het model te kunnen trainen en betrouwbare resultaten te verkrijgen [12]. De output van deze modellen bestaat doorgaans uit een voorspelling van de volgende activiteit in het proces met daarbij een waarschijnlijkheidsindicatie. Dit houdt in dat het model een inschatting maakt van welke activiteit hoogstwaarschijnlijk zal volgen op de huidige activiteit in het proces. De waarschijnlijkheidsindicatie geeft aan hoe zeker het model is van deze voorspelling [1][12]. Voorts worden deze modellen ook gebruikt voor het voorspellen van het tijdstip waarop een toekomstige activiteit zal plaatsvinden, evenals voor het voorspellen van het verwachte einde van een proces [37]. Bijgevolg zal er binnen deze masterproef gebruik worden gemaakt van standaard neurale netwerken om de volgende activiteit en het tijdstip van deze activiteit te voorspellen. Hierdoor zijn we in staat het verwachte gedrag van een persoon gedurende een dag te voorspellen en te vergelijken met het werkelijke gedrag dat zich voordoet.

### 2.3 Detecteren van gedragsafwijkingen

Allereerst kunnen afwijkingen in de volgende drie categorieën worden opgedeeld: puntafwijkingen, collectieve afwijkingen en contextuele afwijkingen. Bij puntafwijkingen beschouwen we elke activiteit apart en analyseren we of deze al dan niet afwijkend is ten opzichte van het normale gedrag. Een voorbeeld van een puntafwijking is dat de activiteit douchen normaliter 15 minuten duurt, terwijl we nu 50 minuten vaststellen. Methodes die gebruikt worden voor het detecteren van puntafwijkingen zijn bijvoorbeeld de standaardafwijking en vooraf gedefinieerde waarden. Collectieve afwijkingen beschouwen daarentegen een groep van activiteiten om te bepalen of iets afwijkt van het normaal wenselijk gedrag. Een voorbeeld van een collectieve afwijking is dat we de activiteiten opstaan, douchen, aankleden, eten en sporten verwachten, maar we enkel de activiteiten opstaan, aankleden en eten vaststellen. De contextuele afwijkingen beschouwen op hun beurt dan weer activiteiten binnen een gegeven context. Hierbij zal de context deels bepalen of het gedrag al dan niet afwijkend is [18]. Ondanks dat anomaliedetectie voornamelijk gebeurt op basis van punt- en collectieve afwijkingen, bieden contextuele afwijkingen meer voordelen. Stel dat we in een bepaalde elektriciteitskast een hoog energieverbruik opmerken. Op basis van de weersomstandigheden en de tijd van het jaar blijkt echter dat het energieverbruik toch binnen de normale grenzen valt. Wanneer we louter gebruik zouden maken van punt- en collectieve afwijkingen, zou het energieverbruik onterecht als een afwijking worden geclassificeerd [17]. Om deze reden wordt er steeds meer geopteerd om gebruik te maken van contextuele informatie voor het detecteren van afwijkingen [18][17]. Bijgevolg zullen we contextuele informatie toevoegen aan de

neurale netwerken om accuratere voorspellingen te maken en het aantal onterechte afwijkingen te verminderen.


Zoals reeds aangehaald focust anomaliedetectie binnen smart homes zich voornamelijk op het detecteren van activiteiten met een ongebruikelijke duurtijd en op het detecteren van activiteiten die overgeslagen worden. De methodes die hiervoor gebruikt worden zijn enerzijds statistische methodes maar anderzijds ook traditionele machine learning methodes [14][29]. Zo wordt er aan de hand van verdelingen en standaardafwijkingen gekeken of de duurtijd van een activiteit afwijkend is [32]. Daarnaast worden clustermethodes, zoals DBSCAN en Self-Organizing Mapping (SOM), gebruikt om afwijkingen te achterhalen. Deze methodes zijn namelijk in staat om clusters van normale activiteiten te vormen. Deze clusteranalyse wordt steeds gedaan op basis van twee dimensies, namelijk het tijdstip van de dag en de duurtijd van een activiteit. Vervolgens worden er clusters gevormd en de daarbij horende centroids berekend. Wanneer bijgevolg de afstand tussen een datapunt en de centroid groter is dan de gemiddelde afstand van alle datapunten in een cluster tot de centroid, wordt het datapunt als een afwijking geclassificeerd. In dit geval vertegenwoordigt elk datapunt een activiteit die plaatsvindt op een specifiek tijdstip en een bepaalde duurtijd heeft [29][17][18][14]. Voorts worden sequence mining en pattern mining methodes gebruikt om te achterhalen of activiteiten worden overgeslagen [36][5]. Zoals eerder vermeld is er in de literatuur weinig onderzoek gevoerd omtrent het detecteren van activiteiten die plaatsvinden op ongebruikelijke tijdstippen [31]. De geringe onderzoeken die hieromtrent bestaan, maken daarentegen enkel gebruik van clustermethodes waarbij een activiteit pas als afwijkend wordt beschouwd wanneer deze niet past binnen de cluster en daarbovenop nog eens aanzienlijk langer duurt [29][17]. Een nadeel van deze methode is dat bepaalde afwijkingen niet worden opgemerkt, namelijk wanneer ze niet significant langer duren dan de normale activiteiten binnen de cluster of dicht bij de centroid gelegen zijn. Bijvoorbeeld, als een persoon 's nachts twee uren televisie kijkt en de gemiddelde duurtijd van activiteiten in die cluster bedraagt 2 uren, zal dit ten onrechte als normaal gedrag beschouwd worden. Bijgevolg zullen we in deze masterproef gebruik maken van statistische methodes, waaronder t-testen en de daarbij horende verwerpingsgebieden, om ook deze afwijkingen op te sporen.

### 3 NN Methode

In deze sectie zullen we de voorgestelde methode, die we vanaf nu de NN methode zullen noemen, bespreken. In Figuur 1 geeft het globale stappenplan van de NN methode weer. We vertrekken bij deze methode vanuit input data die meer specifiek bestaat uit activiteiten met bijhorende timestamps waaruit variabelen zoals de dag van de week en het uur afgeleid kunnen worden. Deze gegevens worden vervolgens als input gebruikt voor de twee neurale netwerken die respectievelijk de volgende activiteit en het daarbij horende tijdstip voorspellen. Om het tijdstip van de volgende activiteit te voorspellen, dienen we te weten welke activiteit de volgende zal zijn. Daarom heeft dit neurale netwerk niet alleen de input data nodig, maar ook de output van het neurale netwerk dat de volgende activiteit voorspelt. Dit wordt aangegeven door de verticale stippellijn in Figuur 1. De twee neurale netwerken worden vervolgens voor de gehele test dataset uitgevoerd. Voorts zullen we aan de hand van de verkregen tijdstippen de output van de neurale netwerken opdelen in dagen. Hierdoor verkrijgen we een overzicht van alle activiteiten met bijhorende tijdstippen die een persoon gedurende een dag naar verwachting uitvoert. Dit zal bijgevolg het verwachte gedrag van een persoon weerspiegelen, hetgeen we vervolgens kunnen vergelijken met het werkelijke, waargenomen gedrag. Dit doen we door de voorspelde en werke-



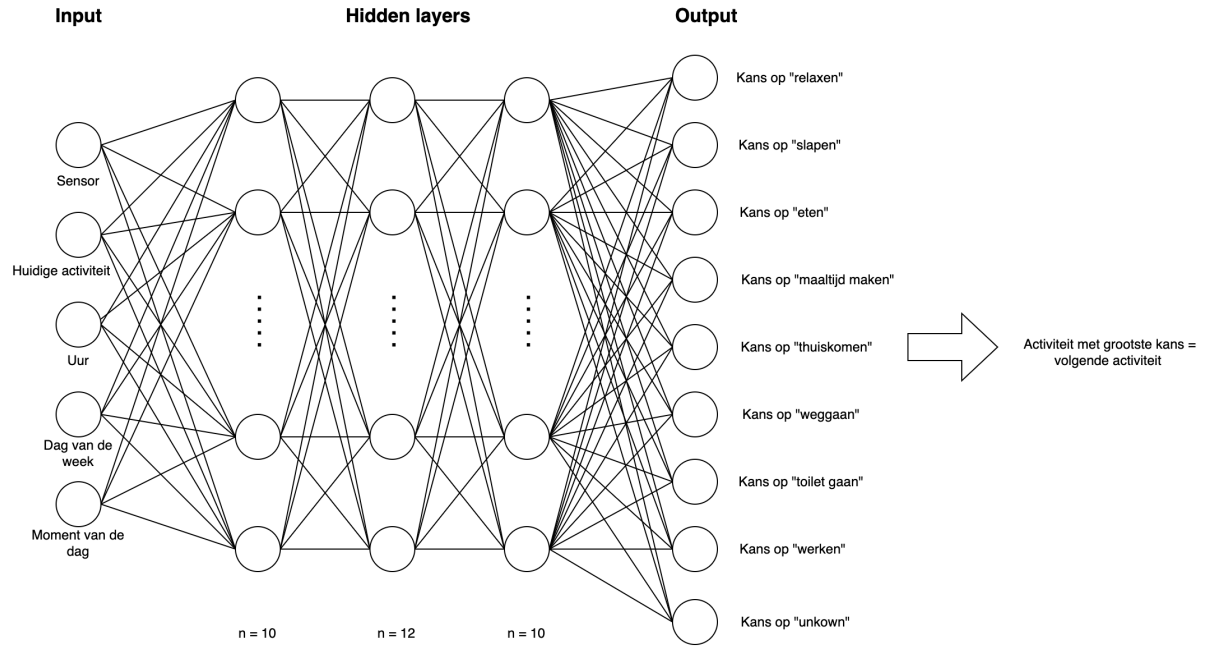
lijke gegevens van een dag visueel weer te geven in een horizontaal gestapelde barplot. Op deze manier kunnen we met het blote oog reeds gedragsafwijkingen tussen het werkelijke en verwachte gedrag vaststellen. Vervolgens worden er t-testen uitgevoerd voor elke activiteit die op een dag plaatsvindt. Deze t-test resultaten worden vervolgens getoetst aan een verwerpsgebied om te bepalen of er significante gedragsafwijkingen in de tijd optreden. In wat volgt zullen we de verschillende stappen van de NN methode in meer detail bespreken. Ter verduidelijking zullen we de stappen toelichten aan de hand van een voorbeeld.




Figuur 1: Globale stappenplan NN methode

Zoals hierboven aangehaald zullen we twee neurale netwerken ontwerpen. De reden dat we voor standaard neurale netwerken kiezen, is omdat deze methode betere resultaten oplevert dan traditionele machine learning methodes [28]. Het eerste neurale netwerk zal in staat zijn de volgende activiteit te voorspellen, daar waar het tweede neurale netwerk het tijdstip voorspelt waarop de volgende activiteit van het eerste neurale netwerk plaatsvindt. De neurale netwerken zullen, zoals eerder vermeld, gebruik maken van contextuele inputvariabelen zoals het huidige tijdstip, de dag van de week en de sensor die getriggerd wordt. Uit onze bevindingen bleek dat hierdoor zowel de accurateheid toenam als het aantal onterechte afwijkingen verminderde. De inputvariabelen die we bijgevolg zullen gebruiken voor het neurale netwerk die de volgende activiteit voorspelt, zijn als volgt: huidige activiteit, huidige uur, dag van de week, moment van de dag en de sensor die getriggerd wordt. De inputvariabelen die we zullen gebruiken voor het neurale netwerk die het volgende tijdstip voorspelt, zijn als volgt: huidige activiteit, huidige uur, huidige tijdstip, dag van de week, moment van de dag en de eerstvolgende activiteit in de toekomst zoals voorspeld door het eerste neurale netwerk. Deze twee neurale netwerken worden respectievelijk in Figuur 2 en 3 weergegeven. Voor de outputlaag van de neurale netwerken maken we gebruik van de activeringsfunctie softmax. De output van de neurale netwerken bestaat meer specifiek uit een reeks van outputnodes, waarbij elke outputnode de kans voorstelt dat een bepaalde activiteit of tijdstip de volgende zal zijn. Bij het neurale netwerk dat het volgende tijdstip voorspelt, merken we op dat de outputlaag 72 nodes bevat. De reden hiervoor is dat de tijd tot op het kwartier nauwkeurig geschat wordt. In de secties methodologie en resultaten zullen we dieper ingaan op de keuzes van de hyperparameters die bepaald werden aan de hand van *grid search*.

Eens de neurale netwerken getraind zijn, laten we ze lopen over de gehele test dataset. Zo verkrijgen we een overzicht van alle activiteiten met bijhorende tijdstippen die een persoon gedurende deze test periode naar verwachting uitvoert. Vervolgens werden deze reeksen aan activiteiten en bijhorende tijdstippen opgedeeld in dagen. Zoals reeds aangehaald zullen we vervolgens het verwachte en werkelijke gedrag per dag in een horizontaal gestapelde barplot gieten, waarbij de x-as de uren van de dag voorstelt en een bar een activiteit weerspiegelt.



Figuur 2: Neuraal netwerk: voorspellen volgende activiteit




Figuur 3: Neuraal netwerk: voorspellen volgende tijdstip

We zullen dit illustreren aan de hand van een voorbeeld. Voor een bepaalde dag uit de test dataset verkrijgen we bijvoorbeeld volgende opeenvolgende reeksen van voorspelde activiteiten en bijhorende tijdstippen:

- **Voorspelde activiteiten** = ['Sleeping', 'Meal Preparation', 'Eating', 'Work', 'Meal Preparation', 'Eating', 'Relax', 'Work', 'Meal Preparation', 'Eating', 'Relax', 'Sleeping', 'Sleeping']
- **Voorspelde tijdstippen** = [0h, 7h, 7h30, 8h, 12h, 12h30, 13h, 13h30, 15h15, 18h15, 19h, 19h30, 22h15, 24h]

We gieten deze voorspelde gegevens van de neurale netwerken vervolgens in een horizontaal gestapelde barplot, zoals weergegeven in Figuur 4. Hierdoor wordt het voorspelde en dus verwachte gedrag van een persoon gedurende de dag visueel weergegeven. Hetzelfde kan gedaan worden voor de werkelijke gegevens om zo het daadwerkelijke, waargenomen gedrag van een persoon visueel weer te geven. Vervolgens worden deze twee barplots met elkaar vergeleken om met het blote oog al eventuele verschillen vast te kunnen stellen. Op basis van Figuur 4 constateren we bijvoorbeeld een gedragsafwijking gedurende de nacht. Dit wordt in de figuur aangeduid met een zwarte cirkel. De persoon staat namelijk op om te ontspannen, bijvoorbeeld door televisie te kijken, wat ongebruikelijk is voor dat tijdstip. De plot van het verwachte gedrag geeft namelijk aan dat de persoon normaal gesproken gedurende deze periode zou slapen.



Figuur 4: Voorbeeld barplot

Om vervolgens te bepalen of het waargenomen verschil in Figuur 4 significant is, worden er t-testen uitgevoerd. Meer specifiek zal er voor elke activiteit die gedurende deze dag heeft plaatsgevonden een t-test worden uitgevoerd. De t-test is een statistische test die in dit geval wordt gebruikt om te bepalen of er een significant verschil optreedt tussen het werkelijke en verwachte gedrag van een persoon gedurende bepaalde tijdsperiodes [19]. Het gedrag van de persoon wordt gekwantificeerd aan de hand van de duurtijd van activiteiten op elk uur. Doordat we twee verschillende groepen aan gegevens hebben, namelijk het verwachte en werkelijke gedrag van een

persoon, zullen we werken met gekoppelde metingen. Aan de hand van deze gekoppelde metingen kunnen we het gemiddelde van beide groepen berekenen en vergelijken. Meer specifiek zullen we de gemiddelde duurtijden van activiteiten gedurende bepaalde tijdsperiodes berekenen. De reden dat we geen t-test uitvoeren over de gehele dag maar per tijdsperiode, is omdat kleine verschillen in duurtijden van een bepaalde tijdsperiode de grote verschillen van een andere tijdsperiode kunnen maskeren. Dit zorgt ervoor dat de significante verschillen minder prominent naar voren komen dan ze daadwerkelijk zijn. Bijgevolg zullen we een dag evenredig in de volgende vier tijdsperiodes opdelen:

- De nacht: 0 uur tot 6 uur.
- De voormiddag: 6 uur tot 12 uur.
- De namiddag: 12 uur tot 18 uur.
- De avond: 18 uur tot 24 uur.

Voor elke activiteit binnen een gegeven tijdsperiode zal er dan worden nagegaan of de NN methode een afwijking detecteert. Kortom zal er aan de hand van de berekende gemiddeldes en bijhorende t-testen gekeken worden of er binnen een tijdsperiode significante verschillen in activiteiten plaatsvinden. Wanneer we binnen een bepaalde tijdsperiode een of meerdere afwijkingen van activiteiten detecteren, kunnen we stellen dat er gedurende die tijdsperiode ongebruikelijk gedrag plaatsvindt. Hiervoor dienen we eerst voor elke activiteit in de gegeven tijdsperiode de t-waarde te berekenen. Deze t-waarde wordt vervolgens afgetoetst aan een verwerpingsgebied om te achterhalen of er een significant verschil optreedt. Wanneer namelijk de berekende t-waarde van een activiteit in het verwerpingsgebied ligt, kunnen we stellen dat er gedurende deze tijdsperiode een significante gedragsafwijking plaatsvindt. Belangrijk op te merken is dat wanneer er een significant verschil wordt vastgesteld, dit enkel geldt voor een bepaalde tijdsperiode. Het impliceert niet per se dat er gedurende heel de dag een gedragsafwijking plaatsvindt. Dit is enkel het geval wanneer er voor alle vier de tijdsperiodes een significant verschil optreedt. In deze masterproef zullen we gebruik maken van een veel gebruikte waarde voor het significantieniveau, namelijk 0.10. Dit significantieniveau biedt een redelijk niveau van zekerheid voor onze schattingen, terwijl het ons ook in staat stelt om de nadruk te leggen op het verkrijgen van inzichten in de haalbaarheid en potentie van de voorgestelde methode [19]. Bijgevolg zal ons verwerpingsgebied er als volgt uitzien:

$$] - \infty, -1.94[\cup]1.94, +\infty[ \tag{1}$$

We zullen dit verder verduidelijken aan de hand van Figuur 4. Meer specifiek zullen we ter illustratie de t-waarde berekenen voor de activiteit 'Relax'. We zullen deze berekening doen voor de tijdsperiode waarin het waargenomen verschil zich voordoet. Zoals eerder aangehaald loopt de tijdsperiode nacht van 0h tot 6h. Daarom zullen we voor zowel het werkelijke als het verwachte gedrag op elk van deze uren gaan kijken hoelang de activiteit 'Relax' duurt. Bijgevolg verkrijgen we voor deze 6 uren de volgende duurtijden in minuten:

- Werkelijke duurtijd activiteit 'Relax' per uur: [0, 30, 60, 60, 45, 0]
- Verwachte duurtijd activiteit 'Relax' per uur: [0, 0, 0, 0, 0, 0]

Bij het berekenen van de t-waarde met behulp van deze gegevens, verkrijgen we een t-waarde van 3.1685 [19]. Aangezien deze waarde binnen het verwerpingsgebied valt, spreken we van een significante gedragsafwijking gedurende deze tijdsperiode. Vervolgens wordt dezelfde berekening

gedaan voor de overige tijdsperiodes en activiteiten van deze dag. Hieruit leiden we af dat er enkel gedurende de tijdsperiode nacht een significant verschil in activiteiten optreedt. Meer informatie over de formules en berekeningen kunnen worden teruggevonden in het boek *Elementary Statistics* van P. Hoel [19].

## 4 Methodologie

### 4.1 Data

We zullen gebruik maken van de Aruba CASAS dataset [9]. Deze dataset bevat sensorgegevens van een persoon op leeftijd. Bovendien werden de gegevens over een periode van 7 maanden verzameld. Om gedrag te kunnen achterhalen, hebben we namelijk een zekere hoeveelheid aan data nodig [18]. Voorts is deze data ook geannoteerd. Dit betekent dat de sensorgegevens reeds voorzien zijn van een zekere omschrijving. In dit geval stelt de omschrijving steeds een activiteit voor. Aangezien het annoteren van data, en meer specifiek het identificeren van activiteiten, een onderzoeksdomen op zich is, valt dit buiten de scope van deze masterproef [41][22]. Om diezelfde reden hebben we gekozen voor een dataset die slechts één persoon omvat [3].

In Figuur 5 wordt een steekproef van deze dataset weergegeven, bestaande uit records met een datum, tijdstip, sensor, conditie, activiteit, status en event. Figuur 6 toont een steekproef van de uitgebreide en gefilterde dataset die is voorbereid voor het experiment zelf. Allereerst werden de records zodanig gefilterd zodat elk opeenvolgend record een nieuwe activiteit met haar bijhorende begintijd weerspiegelt. Om deze dataset vervolgens uit te breiden, werden er drie extra contextuele attributen toegevoegd voor elk record, namelijk het moment van de dag, de weekdag en het uur. Bovendien werden er nog twee extra kolommen toegevoegd om de volgende activiteit en het daarbij horende tijdstip voor elk record weer te geven. Deze informatie is noodzakelijk om de output van de neurale netwerken, die we zullen ontwerpen, te bepalen. Ten slotte werden variabelen, zoals de conditie, de status en het event, die overbodig zijn voor het experiment verwijderd. Uiteraard bevat de dataset meer activiteiten dan alleen diegene die in deze steekproef worden weergegeven. De volledige lijst aan activiteiten is als volgt: relaxen, slapen, maaltijd maken, eten, weggaan, thuiskomen, werken, in de nacht naar het toilet gaan, afwassen en het uitvoeren huishoudelijke taken.

	DATE	TIME	SENSOR	CONDITION	ACTIVITY	STATUS	EVENT
0	2010-11-04	00:03:50.209589	M003	ON	Sleeping	begin	Sleeping,begin
1	2010-11-04	05:40:43.642664	M003	OFF	Sleeping	end	Sleeping,end
2	2010-11-04	05:40:51.303739	M004	ON	Bed_to_Toilet	begin	Bed_to_Toilet,begin
3	2010-11-04	05:43:30.279021	M004	OFF	Bed_to_Toilet	end	Bed_to_Toilet,end
4	2010-11-04	05:43:45.7324	M003	ON	Sleeping	begin	Sleeping,begin

Figuur 5: Steekproef Aruba CASAS dataset

	DATE	TIME	SENSOR	ACTIVITY	MOMENT_OF_DAY	DAY_OF_WEEK	HOOR	NEXT1	NEXT_TIME
0	2010-11-04	00:03:50.209589	M003	Sleeping	night	Thursday	0	Bed_to_Toilet	05:40:51.303739
1	2010-11-04	05:40:51.303739	M004	Bed_to_Toilet	night	Thursday	5	Sleeping	05:43:45.7324
2	2010-11-04	05:43:45.7324	M003	Sleeping	night	Thursday	5	Meal_Preparation	08:33:52.929406
3	2010-11-04	08:33:52.929406	M018	Meal_Preparation	morning	Thursday	8	Relax	09:29:23.223133
4	2010-11-04	09:29:23.223133	M009	Relax	morning	Thursday	9	Meal_Preparation	09:54:58.753743

Figuur 6: Steekproef uitgebreide en gefilterde dataset

Om deze dataset als input te kunnen gebruiken voor de neurale netwerken, is het noodzakelijk de categorische gegevens om te zetten naar numerieke waarden. Hiervoor zullen we gebruik maken van one-hot encoding [20][28][16]. Voorts zal de data volgordegewijs worden opgesplitst in een training, validatie en test dataset. Hiervoor hanteren we een veel gebruikte verhouding, namelijk de 70/15/15 verhouding [25]. Het neurale netwerk zal voorspellingen leren maken op basis van de training dataset. Vervolgens laat de validatie dataset ons toe om enerzijds overfitting tegen te gaan en anderzijds de parameters van het neurale netwerk verder te verfijnen. Ten slotte wordt de test dataset gebruikt om de performantie en generalisatie van het neurale netwerk te bepalen [25][38].

Bovendien zullen we de test dataset gebruiken om handmatig gedragsafwijkingen in de tijd te detecteren. Dit doen we zodat we achteraf kunnen evalueren hoe goed de NN methode is in het detecteren van deze gedragsafwijkingen. Voor deze analyse zullen we meer specifiek gebruik maken van de verdeling van activiteiten gedurende de dag. Concreet hebben we de activiteiten in een grafiek gegoten waarbij de x-as de uren van de dag vertegenwoordigt en de y-as het aantal observaties. Hierdoor kunnen we bepalen op welke momenten bepaalde activiteiten zich hoofdzakelijk voordoen. Zo merkten we bijvoorbeeld op dat de persoon zelden in de vroege namiddag slaapt. Indien we dus in de test dataset vaststellen dat de persoon in de vroege namiddag heeft geslapen, zullen we dit als een gedragsafwijking in de tijd classificeren. Voorts zullen we ook gebruik maken van algemene kennis over menselijk gedrag. Zo weten we bijvoorbeeld dat eten om 12 uur gebruikelijk is, terwijl eten om 3 uur in de nacht eerder als uitzonderlijk en afwijkend beschouwd wordt. Deze algemene kennis wordt eerder ter verificatie van de verdelingen gebruikt. Kortom zal er altijd eerst naar de verdeling van activiteiten gekeken worden alvorens we ons berusten op algemene kennis. Zoals in de vorige sectie aangehaald, zullen we gedragsafwijkingen per tijdsperiode detecteren. Aangezien de test dataset uit 44 dagen bestaat, geeft dit ons een totaal van 176 tijdsperiodes. Wanneer we de test dataset manueel analyseerden op basis van de verdelingen van activiteiten van de persoon en algemene kennis over menselijk gedrag, kwamen we tot de vaststelling dat er in 58 tijdsperiodes een gedragsafwijking plaatsvond.

## 4.2 Bepalen van hyperparameters

Een neurale netwerk staat of valt met het bepalen van de meest optimale waarden voor de hyperparameters [2]. Deze hebben namelijk een grote invloed op de performantie en de bruikbaarheid van een neurale netwerk [42][13]. Hyperparameters van een neurale netwerk zijn onder andere de activeringsfuncties, het aantal verborgen lagen, het aantal knooppunten per laag en de *learning rate* [13]. Een veel gebruikte en veelbelovende methode voor het optimaliseren van hyperparameters is *grid search*. Deze methode beschouwt een set van hyperparameters en geeft voor elke hyperparameter de meest optimale waarden terug [30][27]. Bijgevolg zullen we in deze

masterproef gebruik maken van *grid search* voor het bepalen van de waarden van de hyperparameters. In Tabel 1 worden de sets van hyperparameters weergegeven die we zullen testen aan de hand van *grid search*. Meer informatie over de betekenis en werking van de verschillende hyperparameters kan worden teruggevonden in de paper van K. Shiruru (2016) [33].

Tabel 1: Hyperparameters *grid search*

Hyperparameters	waarden
Aantal <i>hidden layers</i>	1, 2, 3, 4, 5, 6, 7, 8, 9 en 10
Aantal nodes per <i>hidden layer</i>	2, 5, 8, 10, 12, 15, 18, 20, 25, 30, 35, 40 en 45
Activeringsfunctie	Softmax, softplus, softsign, relu, tanh, sigmoid, hard sigmoid en linear
Batch grootte	10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 80 en 100
Epochs	10, 50, 100, 200, 300, 400, 500, 600, 700, 800, 900 en 1000
<i>Learning rate</i>	0.001, 0.01, 0.1, 0.2 en 0.3.
Optimalisatiefunctie	SGD, RMSprop, Adagrad, Adadelata, Adam, Adamax en Nadam
Gewicht initialisatie	Uniform, lecu uniform, normal, zero, gloriot normal, gloriot uniform, he normal en he uniform

### 4.3 Validatie

Zoals eerder besproken maken bestaande onderzoeken gebruik van clustermethodes om gedragsafwijkingen in de tijd te detecteren [29][17][14]. Een nadeel van deze aanpak is dat bepaalde afwijkingen niet worden opgemerkt, namelijk wanneer ze niet significant langer duren dan de normale activiteiten binnen de cluster of dicht bij de centroid gelegen zijn. Om te achterhalen of de NN methode beter presteert dan de bestaande clustermethodes, zullen we beide methodes uitvoeren op de test dataset. We hebben gekozen voor K-Means als de bestaande clustermethode omdat deze methode betere clusters genereert voor onze dataset dan de andere methodes, zoals DBSCAN of Self-Organizing Mapping. Bij het uitvoeren van K-Means passen we dezelfde logica toe als de bestaande clustermethodes. Deze clusteranalyse wordt steeds gedaan op basis van twee dimensies, namelijk het tijdstip van de dag en de duurtijd van een activiteit. Vervolgens worden er clusters gevormd en de daarbij horende centroids berekend. Wanneer bijgevolg de afstand tussen een datapunt en de centroid groter is dan de gemiddelde afstand van alle datapunten in een cluster tot de centroid, wordt het datapunt als een afwijking geclassificeerd. De afstand wordt telkens berekend aan de hand van de euclidsiche afstandsfunctie. Bovendien vertegenwoordigt elk datapunt een activiteit die plaatsvindt op een specifiek tijdstip en een bepaalde duurtijd heeft [29][17][18][14]. Zoals reeds aangehaald zullen we voor elke activiteit binnen een gegeven tijdsperiode nagaan of de NN methode en de bestaande clustermethode een afwijking detecteren. Dit betekent dat we voor elk van de 176 tijdsperiodes zullen nagaan of er een gedragsafwijking plaatsvindt. Wanneer de methode een of meerdere afwijkingen van activiteiten binnen een bepaalde tijdsperiode detecteert, stellen we dat er gedurende die tijdsperiode ongebruikelijk gedrag plaatsvindt. Ten slotte zullen we analyseren welke methode het meest effectief is in het detecteren van deze afwijkingen. We zullen namelijk dieper inzoomen op de gedetecteerde afwijkingen en beoordelen of deze terecht als afwijking werden geclassificeerd. Zoals hierboven in de data sectie vermeld, zal deze beoordeling gebeuren aan de hand van de verdeling van activiteiten en algemene kennis over gedrag. Meer specifiek zullen we de gedetecteerde afwijkingen van beide methodes vergelijken met de afwijkingen die we zelf handmatig hebben geïdentificeerd in de test dataset.

## 5 Resultaten

Zoals eerder vermeld toont Figuur 2 het neurale netwerk dat we gebruiken om de eerstvolgende activiteit te voorspellen. Wanneer we de optimale waarden voor de hyperparameters testen met behulp van *grid search*, komen we tot de conclusie dat het neurale netwerk het best presteert wanneer het drie *hidden layers* heeft en waarbij elke *layer* respectievelijk 10, 12 en 10 nodes bevat. Om dit neurale netwerk te trainen, opteert *grid search* voor een batch grootte van 35, 800 epochs, een *learning rate* van 0.001 en de optimalisatiefunctie Adam. In Figuur 2 zien we ook dat de laatste outputnode de activiteit *unknown* weergeeft. Het is belangrijk op te merken dat er slechts twee records in de gehele dataset de waarde *unknown* bevatten. Hierdoor zal het neurale netwerk deze activiteit nooit als eerstvolgende activiteit voorspellen. Bovendien heeft het neurale netwerk een accuraatheid op de test dataset van 74 procent, wat een aanvaardbare en realistische score is gezien de gegeven dataset. In Figuur 3 wordt, zoals eerder aangehaald, het neurale netwerk afgebeeld dat in staat is het volgende tijdstip te voorspellen waarop de voorspelde eerstvolgende activiteit zal plaatsvinden. Opnieuw blijkt uit *grid search* dat het neurale netwerk het beste presteert met drie *hidden layers*, waarbij elke *layer* respectievelijk 25, 20 en 15 nodes bevat. Om dit neurale netwerk te trainen, opteert *grid search* voor een batch grootte van 30, 700 epochs, een *learning rate* van 0.001 en de optimalisatiefunctie Adam. Dit neurale netwerk heeft een accuraatheid op de test dataset van 72 procent, wat opnieuw een aanvaardbare en realistische score is gezien de gegeven dataset.

Eens de neurale netwerken getraind waren, voerden we ze uit voor de 44 dagen in onze test dataset. De output die hieruit voortvloeide, gebruikten we vervolgens voor het uitvoeren van de NN methode. Daarnaast werd ook de bestaande K-Means clustermethode op de test dataset uitgevoerd. Zoals in sectie 4 aangehaald, werd er voor elk van de 176 tijdsperiodes gekeken of er een gedragsafwijking plaatsvond. Zoals reeds aangehaald kwamen we tot de vaststelling dat er in 58 tijdsperiodes een gedragsafwijking plaatsvond. Tabel 2 geeft een overzicht van de resultaten van beide methodes weer. Zo merken we op dat de NN methode in 56 van de 176 tijdsperiodes een gedragsafwijking detecteert, wat twee minder is dan de 58 werkelijke afwijkingen in de test dataset. Van deze 56 afwijkingen zijn er slechts 3 onterecht, waardoor de NN methode een kleine foutmarge heeft. Bovendien detecteert de NN methode 91.4% van de werkelijke gedragsafwijkingen, waarbij voornamelijk lichte afwijkingen worden gemist. Hieruit kunnen we concluderen dat de NN methode effectief is in het detecteren van gedragsafwijkingen in de tijd, al is er nog steeds ruimte voor verbetering mogelijk. In tegenstelling tot de NN methode detecteert de bestaande clustermethode op basis van K-Means veel meer afwijkingen. Wanneer we echter dieper ingaan op deze afwijkingen, stellen we vast dat 30.4% van deze afwijkingen onterecht als afwijking geclassificeerd wordt. De voornaamste reden hiervoor is dat datapunten die verder van de centroid verwijderd zijn onterecht als afwijking worden geclassificeerd, terwijl ze eigenlijk normaal gedrag weerspiegelen. Bovendien detecteert de bestaande clustermethode 82.7% van de werkelijke afwijkingen in de test dataset, wat opnieuw een aanvaardbare score is. Echter merken we hierbij op dat dit percentage een stuk lager ligt dan die van de NN methode. Over het algemeen kunnen we dus stellen dat de NN methode effectiever is in het detecteren van gedragsafwijkingen in de tijd dan de bestaande clustermethode. In wat volgt zullen we aan de hand van voorbeelden verklaren waarom beide methodes bepaalde afwijkingen mislopen en bepaalde records onterecht als afwijking geclassificeerd worden.

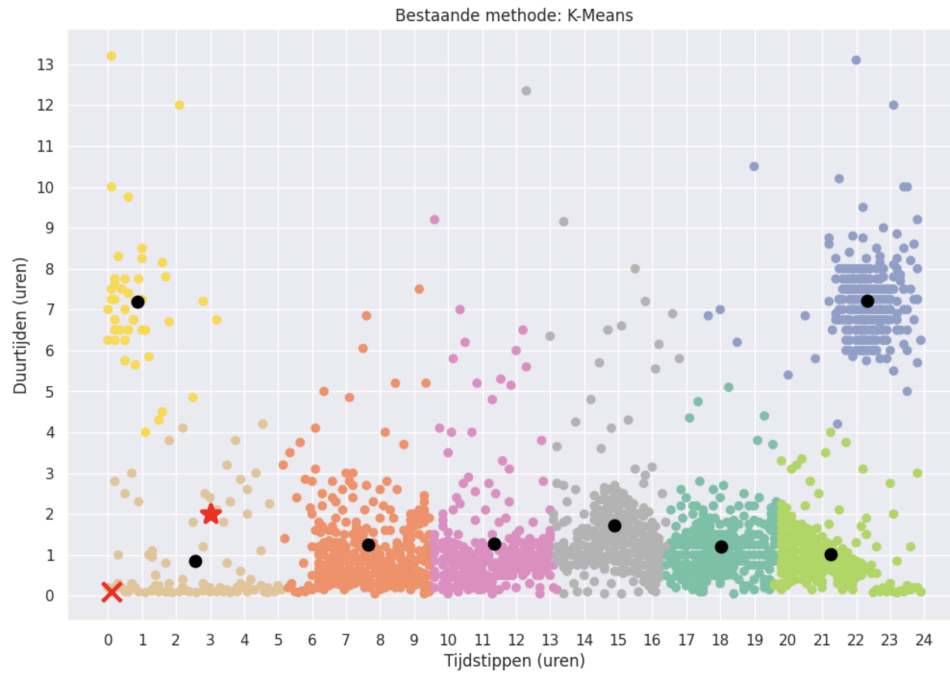


Tabel 2: Resultaten methodes


	<b>NN methode</b>	<b>Bestaande clustermethode</b>
Aantal gedetecteerde afwijkingen	56	68
Aantal correct gedetecteerde afwijkingen	53	48
Percentage correct gedetecteerde afwijkingen	94.6%	70.6 %
Aantal foutief gedetecteerde afwijkingen	3	20
Percentage foutief gedetecteerde afwijkingen	5.4%	30.4%
Aantal werkelijke afwijkingen test dataset	58	58%
Percentage werkelijke afwijkingen dat gedetecteerd wordt	91.4%	82.7%

Allereerst zullen we dieper ingaan op de reden waarom de bestaande clustermethode een aanzienlijk aantal records onterecht als afwijking classificeert en werkelijke afwijkingen over het hoofd ziet. De voornaamste reden hiervoor is dat deze methode zich te zeer focust op de afstand tussen een datapunt en de centroid. In Figuur 7 worden de clusters voor de volledige dataset weergegeven die zijn gecreëerd door de bestaande clustermethode K-Means. Er zijn in totaal 8 clusters, waarbij de zwarte punten de centroids van elke cluster voorstellen. Het rode kruis linksonder geeft het datapunt weer waarbij de persoon om iets na middernacht is opgestaan om enkele minuten naar het toilet te gaan. Wanneer we de verdelingen van de activiteit 'naar het toilet gaan' in beschouwing nemen, zien we dat het gebruikelijk is dat de persoon op dit tijdstip gedurende een korte periode naar het toilet gaat. Nochtans is de afstand van dit datapunt tot de centroid groter dan de gemiddelde afstand van alle datapunten in de cluster tot de centroid. Bijgevolg wordt het door de clustermethode onterecht als afwijking geclassificeerd. Daarnaast geeft de rode ster het datapunt weer waar de persoon om 3 uur in de nacht gedurende 2 uur ontspant, bijvoorbeeld door televisie te kijken. Dit is uiteraard geen normaal gedrag voor dit tijdstip. Toch classificeert de methode dit als normaal gedrag aangezien de afstand van dit datapunt tot de centroid kleiner of gelijk is aan de gemiddelde afstand van alle datapunten in de cluster tot de centroid. Deze twee voorbeelden illustreren waarom de afstand van een punt tot de centroid foutieve classificaties veroorzaakt. In de test dataset kunnen er meerdere gelijkaardige voorbeelden gevonden worden.

Zoals eerder vermeld heeft de NN methode moeite om lichte afwijkingen te detecteren, meer specifiek gedrag dat net genoeg afwijkt om een waarschuwing te genereren. Daarnaast classificeert de methode soms datapunten als afwijking wanneer ze eigenlijk net niet afwijkend genoeg zijn. De NN methode heeft dus moeite met het classificeren van datapunten die op de grens tussen afwijkend en normaal gedrag liggen. We zullen deze beperking illustreren aan de hand van Figuur 8. Hierbij merken we op dat de persoon later is gaan slapen dan verwacht. Wanneer we de verdeling van de activiteit slapen in beschouwing nemen, zien we dat het voorval eerder uitzonderlijk is. Toch classificeert de NN methode dit niet als een afwijking, omdat het een t-waarde van 1.92 oplevert, hetgeen buiten het verwerpingsgebied ligt. Indien de persoon echter 8 minuten later was gaan slapen, verkregen we een t-waarde van 1.95. In dat geval zou het als een afwijking worden beschouwd, aangezien deze waarde wel in het verwerpingsgebied ligt. Dit illustreert hoe slechts enkele minuten het verschil kunnen maken tussen een afwijking of niet. Echter merken we op dat dit enkel geldt voor lichte en twijfelachtige gedragsafwijkingen, waarvan de gevolgen doorgaans minimaal zijn.




Figuur 7: Bestaande clustermethode



Figuur 8: Lichte afwijking

Ten slotte stellen we vast dat de NN methode in staat is alle grote en ernstige afwijkingen te detecteren, daar waar de bestaande clustermethode enkele belangrijke afwijkingen over het hoofd ziet. Zoals eerder aangehaald komt dat laatste voornamelijk doordat er te veel gefocust wordt op de centroid van een cluster. In Figuur 9 zien we bijvoorbeeld dat de persoon zowel in de nacht als over de middag afwijkend gedrag vertoont, meer specifiek gedrag dat we op die momenten niet zouden verwachten. De gedragsafwijking over de middag wordt door zowel de bestaande clustermethode als de NN methode gedetecteerd. De afwijking in de nacht wordt daarentegen enkel door de NN methode gedetecteerd. Hierbij verkrijgen we meer specifiek een t-waarde van 2.27, dewelke in het verwerpingsgebied valt. Wanneer we naar Figuur 7 kijken, zien we dat dit punt zich in de buurt van de rode ster bevindt. Wanneer we de berekening van de bestaande clustermethode uitvoeren, stellen we vast dat de afstand van dit datapunt tot de centroid niet groter is dan de gemiddelde afstand van alle datapunten in de cluster tot de centroid. Bijgevolg zal de bestaande clustermethode dit gedrag niet als afwijking classificeren. Toch is het belangrijk om deze grote afwijkingen te detecteren, aangezien ze kunnen wijzen op alarmerend gedrag. Misschien kon de persoon wel niet slapen omdat hij zich niet goed voelde? Misschien is het een teken van een onderliggende medische aandoening? Door deze afwijkingen te detecteren en vervolgens de oorzaak hiervan te achterhalen, kunnen passende maatregelen worden genomen om verdere gevolgen te voorkomen.



Figuur 9: Grote afwijking

## 6 Conclusie

Het doel van deze masterproef was om een methode voor te stellen die gedragsafwijkingen in de tijd kon detecteren. De reden hierachter was dat anomaliedetectie zich tot op heden voornamelijk focuste op het detecteren van activiteiten met een ongebruikelijke duurtijd of activiteiten

die overgeslagen worden. Nochtans is het van belang om ook gedragsafwijkingen in de tijd te detecteren. De geringe onderzoeken die hieromtrent bestaan, focussen zich daarnaast ook op clustermethodes. Een groot nadeel hierbij is dat activiteiten pas als afwijkend worden beschouwd wanneer deze niet passen binnen de cluster en ook nog eens aanzienlijk langer duren. Hierdoor kunnen bepaalde afwijkingen niet worden opgemerkt, namelijk wanneer ze niet significant langer duren dan de normale activiteiten binnen de cluster of dicht bij de centroid gelegen zijn. Vandaar dat onze methode een aanpak voorstelt die hier wel toe in staat is.

De NN methode bestond meer specifiek uit het ontwerpen van twee neurale netwerken. Het ene neurale netwerk is in staat om de volgende activiteit te voorspellen, terwijl het andere neurale netwerk het tijdstip van de volgende activiteit voorspelt. De output van beide netwerken werd vervolgens gebruikt om het verwachte gedrag van de persoon voor een bepaalde dag weer te geven. Dit werd dan vergeleken met het werkelijke gedrag dat de persoon vertoonde. Belangrijk hierbij is dat alle tijdstippen en activiteiten in beschouwing werden genomen. Om vervolgens te bepalen of er significante verschillen aanwezig waren tussen het verwachte en werkelijke gedrag, werden t-testen en de daarbij horende verwerpingsgebieden berekend en geëvalueerd. Om te achterhalen of de NN methode beter presteert dan de bestaande clustermethodes, werden beide methodes op de test dataset uitgevoerd. Voor de bestaande clustermethode werd er gekozen voor K-Means, aangezien deze methode betere clusters genereerde voor onze dataset dan de andere methodes, zoals DBSCAN of Self-Organizing Mapping. We stelden vast dat de NN methode 91.4% van de werkelijke afwijkingen detecteerde, daar waar de bestaande K-Means methode slechts 82.7% van de werkelijke afwijkingen detecteerde. Voorts had de bestaande K-Means methode een relatief hoge foutmarge van 30.4%, terwijl de foutmarge van de NN methode slechts 5.4% bedroeg. Daarnaast stelden we ook vast dat de NN methode in staat is alle grote en ernstige afwijkingen te detecteren, daar waar de bestaande clustermethode enkele belangrijke afwijkingen over het hoofd ziet. Ten slotte moet gezegd worden dat de NN methode moeite heeft met het classificeren van datapunten die op de grens tussen afwijkend en normaal gedrag liggen. Het gaat hierbij over lichte en twijfelachtige gedragsafwijkingen, waarvan de gevolgen doorgaans minimaal zijn. Over het algemeen kunnen we concluderen dat de NN methode effectief is in het detecteren van gedragsafwijkingen in de tijd en daarbovenop beter presteert dan de reeds bestaande clustermethodes.

Ten slotte zijn er enkele beperkingen verbonden aan de NN methode. Ten eerste bevat de geannoteerde dataset enkel activiteiten op een hoger niveau zoals eten, werken en slapen. Activiteiten op een gedetailleerder niveau zoals het snijden van groeten, stofzuigen en het lezen van een boek, zijn niet beschikbaar. Bijgevolg kunnen we niet garanderen dat de methode effectief is in het detecteren van gedragsafwijkingen in de tijd wanneer we gedetailleerdere input hebben. Bovendien geven de neurale netwerken een accuraatheid van 74 en 72 procent terug. Desondanks dit realistische en aanvaardbare waarden zijn gegeven de dataset, is er nog een redelijke foutmarge aanwezig. Een andere belangrijke uitdaging hierbij is wanneer we de neurale netwerken opnieuw moeten trainen. Als we bijvoorbeeld vaststellen dat we steeds meer afwijkingen detecteren, kan dit te wijten zijn aan mogelijke veranderingen in het gedrag van de persoon. In dergelijke gevallen is het van groot belang om de neurale netwerken opnieuw te trainen met behulp van nieuwe gegevens. Voorts werden we gedwongen de tijdsvoorspellingen af te ronden op een kwartier, waardoor we een zekere nauwkeurigheid mislopen. Daarnaast zijn er ook nog enkele uitdagingen weggelegd voor toekomstig onderzoek. Een eerste belangrijke uitdaging is het kunnen detecteren van deze afwijkingen in een omgeving waar meerdere personen aanwezig

zijn. Een tweede belangrijke uitdaging is het annoteren van real-time sensor data om afwijkingen direct te kunnen detecteren en waar nodig bij te sturen.

## Referenties

1. AL-JEBRNI, A., CAI, H., AND JIANG, L. Predicting the Next Process Event Using Convolutional Neural Networks. In *2018 IEEE International Conference on Progress in Informatics and Computing (PIC)* (Dec. 2018).
2. ALIBRAHIM, H., AND LUDWIG, S. A. Hyperparameter Optimization: Comparing Genetic Algorithm against Grid Search and Bayesian Optimization. In *2021 IEEE Congress on Evolutionary Computation (CEC)* (June 2021).
3. AN, J., CHENG, Y., HE, X., GUI, X., WU, S., AND ZHANG, X. Multiuser Behavior Recognition Module Based on DC-DMN. *IEEE Sensors Journal* (Feb. 2022).
4. BANOVIC, N., WANG, A., JIN, Y., CHANG, C., RAMOS, J., DEY, A., AND MANKOFF, J. Leveraging Human Routine Models to Detect and Generate Human Behaviors. In *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems* (2017).
5. BRDICZKA, O., SU, N. M., AND BEGOLE, J. B. Temporal task footprinting: identifying routine tasks by their temporal patterns. In *Proceedings of the 15th international conference on Intelligent user interfaces* (Feb. 2010).
6. CASTELLI, N., Ogonowski, C., JAKOBI, T., STEIN, M., STEVENS, G., AND WULF, V. What Happened in my Home? An End-User Development Approach for Smart Home Data Visualization. In *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems* (2017).
7. CHAN, M., ESTÈVE, D., ESCRIBA, C., AND CAMPO, E. A review of smart homes—Present state and future challenges. *Computer Methods and Programs in Biomedicine* (July 2008).
8. CHOI, S., KIM, E., AND OH, S. Human behavior prediction for smart homes using deep learning. In *2013 IEEE RO-MAN* (Aug. 2013).
9. COOK, D. J., CRANDALL, A. S., THOMAS, B. L., AND KRISHNAN, N. C. CASAS: A Smart Home in a Box. *Computer* (July 2013).
10. DE-LA-HOZ-FRANCO, E., ARIZA-COLPAS, P., QUERO, J. M., AND ESPINILLA, M. Sensor-Based Datasets for Human Activity Recognition – A Systematic Review of Literature. *IEEE Access* (2018).
11. DEBES, C., MERENTITIS, A., SUKHANOV, S., NIESSEN, M., FRANGIADAKIS, N., AND BAUER, A. Monitoring Activities of Daily Living in Smart Homes: Understanding human behavior. *IEEE Signal Processing Magazine* (Mar. 2016).
12. DI FRANCESCO MARINO, C., GHIDINI, C., MAGGI, F. M., AND MILANI, F. Predictive Process Monitoring Methods: Which One Suits Me Best?
13. DIAZ, G. I., FOKOUE-NKOUTCHE, A., NANNICINI, G., AND SAMULOWITZ, H. An effective algorithm for hyperparameter optimization of neural networks. *IBM Journal of Research and Development* (July 2017).
14. FAHAD, L. G., AND TAHIR, S. F. Activity recognition and anomaly detection in smart homes. *Neurocomputing* (Jan. 2021).
15. FELDMAN, M. S., PENTLAND, B. T., D’ADDERIO, L., DITTRICH, K., RERUP, C., AND SEIDL, D. What Is Routine Dynamics? In *Cambridge Handbook of Routine Dynamics*, B. T. Pentland, C. Rerup, D. Seidl, K. Dittrich, L. D’Adderio, and M. S. Feldman, Eds. 2021.
16. HARANE, N., AND RATHI, S. Comprehensive Survey on Deep Learning Approaches in Predictive Business Process Monitoring. In *Modern Approaches in Machine Learning and Cognitive Science: A Walkthrough: Latest Trends in AI*, V. K. Gunjan, J. M. Zurada, B. Raman, and G. R. Gangadharan, Eds. 2020.
17. HAYES, M. A., AND CAPRETZ, M. A. Contextual Anomaly Detection in Big Sensor Data. In *2014 IEEE International Congress on Big Data* (June 2014).
18. HELA, S., AMEL, B., AND BADRAN, R. Early anomaly detection in smart home: A causal association rule-based approach. *Artificial Intelligence in Medicine* (Sept. 2018).

19. HOEL, P. G. Elementary statistics. *Elementary statistics* (1960).
20. KETYKÓ, I., MANNHARDT, F., HASSANI, M., AND VAN DONGEN, B. F. What averages do not tell: predicting real life processes with sequential deep learning. In *Proceedings of the 37th ACM/SIGAPP Symposium on Applied Computing* (2022).
21. KONIOS, A., GARCIA-CONSTANTINO, M., CHRISTOPOULOS, S.-R., MUSTAFA, M. A., EKERETE, I., SHEWELL, C., NUGENT, C., AND MORRISON, G. Probabilistic Analysis of Temporal and Sequential Aspects of Activities of Daily Living for Abnormal Behaviour Detection.
22. KRISHNAN, N. C., AND COOK, D. J. Activity recognition on streaming sensor data. *Pervasive and Mobile Computing* 10 (Feb. 2014).
23. LAGO, P., RONCANCIO, C., AND JIMÉNEZ-GUARÍN, C. Learning and managing context enriched behavior patterns in smart homes. *Future Generation Computer Systems* (Feb. 2019).
24. LEOTTA, F., MECELLA, M., AND SORA, D. Visual process maps: a visualization tool for discovering habits in smart homes. *Journal of Ambient Intelligence and Humanized Computing* (May 2020).
25. LEVER, J., KRZYWINSKI, M., AND ALTMAN, N. Points of Significance: Model selection and overfitting. *Nature Methods* (Sept. 2016).
26. LIANG, T., ZENG, B., LIU, J., YE, L., AND ZOU, C. An Unsupervised User Behavior Prediction Algorithm Based on Machine Learning and Neural Network For Smart Home. *IEEE Access* (2018).
27. LOSHCHILOV, I., AND HUTTER, F. CMA-ES for Hyperparameter Optimization of Deep Neural Networks.
28. NEU, D. A., LAHANN, J., AND FETTKE, P. A systematic literature review on state-of-the-art deep learning methods for process prediction. *Artificial Intelligence Review* (Feb. 2022).
29. NOVÁK, M., JAKAB, F., AND LAIN, L. Anomaly Detection in User Daily Patterns in Smart-Home Environment, 2013.
30. PONTES, F. J., AMORIM, G. F., BALESTRASSI, P. P., PAIVA, A. P., AND FERREIRA, J. R. Design of experiments and focused grid search for neural network parameter optimization. *Neurocomputing* (Apr. 2016).
31. RASHIDI, P., AND COOK, D. J. Keeping the Resident in the Loop: Adapting the Smart Home to the User. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* (Sept. 2009).
32. SHAHID, Z. K., SAGUNA, S., AND ÅHLUND, C. Detecting Anomalies in Daily Activity Routines of Older Persons in Single Resident Smart Homes: Proof-of-Concept Study. *JMIR Aging* (Apr. 2022).
33. SHIRURU, K. AN INTRODUCTION TO ARTIFICIAL NEURAL NETWORK. *International Journal of Advance Research and Innovative Ideas in Education* (Sept. 2016).
34. SUKOR, A. S. A., SETCHI, R., AND JI, Z. Abnormality Detection Approach in Smart Homes using Case-based Reasoning. In *2020 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)* (June 2020).
35. SURYADEVARA, N. K., MUKHOPADHYAY, S. C., WANG, R., AND RAYUDU, R. K. Forecasting the behavior of an elderly using wireless sensors data in a smart home. *Engineering Applications of Artificial Intelligence* (Nov. 2013).
36. TAX, N., SIDOROVA, N., HAAKMA, R., AND VAN DER AALST, W. M. P. Mining local process models. *Journal of Innovation in Digital Ecosystems* (Dec. 2016).
37. TAYMOURI, F., ROSA, M. L., ERFANI, S., BOZORGI, Z. D., AND VERENICH, I. Predictive Business Process Monitoring via Generative Adversarial Nets: The Case of Next Event Prediction. In *Business Process Management* (2020).
38. VALIPOUR, M. Optimization of neural networks for precipitation analysis in a humid region to detect drought and wet year alarms. *Meteorological Applications* (2016).
39. VAVILOV, D., MELEZHNIK, A., AND PLATONOV, I. Smart home user's behavior prediction. In *2013 IEEE Third International Conference on Consumer Electronics Berlin (ICCE-Berlin)* (Sept. 2013).
40. XU, G., LIU, M., LI, F., ZHANG, F., AND SHEN, W. User behavior prediction model for smart home using parallelized neural network algorithm. In *2016 IEEE 20th International Conference on Computer Supported Cooperative Work in Design (CSCWD)* (May 2016).

41. ZHANG, N., YAN, Y., ZHU, X., AND WANG, J. A novel user behavior prediction model based on automatic annotated behavior recognition in smart home systems. *China Communications* (Sept. 2022).
42. ZHANG, X., CHEN, X., YAO, L., GE, C., AND DONG, M. Deep Neural Network Hyperparameter Optimization with Orthogonal Array Tuning. In *Neural Information Processing* (2019).