

## Samenvatting

Lopen is een van de meest voorkomende dagelijkse fysieke activiteiten. Het loopgedrag geeft inzicht in de gezondheid doordat het de coördinatie van het musculoskeletale-, het cardiorespiratoire systeem en het zenuwstelsel weerspiegelt. Met de komst van draagbare sensortechnologieën, zoals accelerometers, is het mogelijk geworden om het lopen in de dagelijkse leefomgevingen te registreren. Met gebruik van data analysemethoden en artificiële intelligentie (AI) kan uit de accelerometer signalen informatie worden gehaald, waarmee inzicht wordt gekregen over veranderingen in het lopen als gevolg van het ouder worden of door lage rugklachten. AI-gestuurde loopanalyse heeft een nauwkeurighedsniveau dat vergelijkbaar is met die van getrainde klinici. De prestaties van de voorspelling en nauwkeurigheid gaat echter gepaard met een toenemende complexiteit van de AI-modellen waarbij het lastig is te beschrijven op grond waarvan het model tot zijn uitkomst komt. Deze zogenaamde “black-box” maakt de toepassing ervan in de kliniek lastig. Klinische experts en patiënten zullen moeite hebben om de AI-gestuurde loopanalyse te vertrouwen omdat niet altijd duidelijk is hoe de uiteindelijke resultaten tot stand zijn gekomen. Daarnaast is wetgeving omtrent het gebruik van AI in de zorg nog in ontwikkeling. Explainable AI (XAI), een recente ontwikkeling beoogt deze uitdagingen aan te pakken en de transparantie en interpreteerbaarheid van AI-modellen te verbeteren. Het kan bijdragen aan het creëren van meer inzicht in de achtergrond van de uitkomst van de modellen en bijdragen aan het vertrouwen tussen AI-gestuurde loopanalyses en de gebruikers. Daarnaast kan XAI waardevolle inzichten en kennis genereren over het begrijpen van veranderend bewegen als gevolg van leeftijd en aandoeningen. Daarom was het doel van dit proefschrift om het begrip van beweging, met name het loopgedrag, bij gezonde oudere volwassenen en patiënten met rugpijn te verbeteren, door gebruik te maken van inzichten uit XAI (**hoofdstuk 1**).

Conventionele Machine Learning (CML) wordt vaak gebruikt voor het classificeren van verschillende looppatronen op basis van een grote verscheidenheid aan loopparameters, zoals spatio-temporele parameters (stap lengte, stap tijd, snelheid) en dynamische parameters (stabiliteit, vloeiendheid, frequentie) van het lopen. Deze loopparameters worden afzonderlijk berekend vanuit accelerometer signalen, en dit is doorgaans een arbeidsintensief proces met veel voorbewerkingen. Bovendien wordt de berekening van de loopparameters meestal offline gedaan, waardoor real-time toepassingen zoals het monitoren van het looppatronen van oudere volwassenen in dagelijkse leefomgevingen, met directe terugkoppeling niet mogelijk is. **Hoofdstuk 2** heeft als doel om te onderzoeken of met Deep Learning (DL) modellen, op basis van accelerometer signalen van drie minuten lopen, de noodzaak van het vooraf berekenen van aparte loopvariabelen voor classificatiemodellen kan worden vermeden. De prestatie van modellen voor de classificatie van looppatronen van mensen met verschillende leeftijd wordt in dit hoofdstuk vergeleken. De prestaties van vijf DL-modellen (met het ‘ruwe’ accelerometer signaal als invoer) is vergeleken met vier CML-

modellen (met afzonderlijke loopvariabelen). De resultaten toonden aan dat alle DL-modellen de CML-modellen overtroffen, met een area under the curve (AUC) van meer dan 0,94, vergeleken met de hoogste AUC van 0,83 van het beste CML-model. Deze bevindingen benadrukten niet alleen de superioriteit van DL, maar suggereerden ook dat DL waardevolle loopuitkomsten heeft geleerd die leeftijdsgelateerde veranderingen in het lopen weerspiegelen, welke door de CML niet werden geïdentificeerd. Daarnaast beschrijft het hoofdstuk de effecten van verschillende venstergroottes van data selectie op de classificatieprestaties. Verschillende venstergroottes resulteren in verschillende aantallen van opeenvolgende loopcycli die gebruikt worden als input voor het DL-model. Er werd geconstateerd dat Convolutionele Neurale Netwerken (CNN) in staat waren om op basis van een enkele loopcyclus onderscheid te maken tussen volwassenen en oudere volwassenen, terwijl Recurrent Neural Network (RNN) de relaties over de tijd tussen loopcycli meeneemt in de classificatie.

Voortbouwend op de inzichten uit hoofdstuk 2, heeft het onderzoek dat in **hoofdstuk 3** wordt beschreven als doel om te onderzoeken wat DL-modellen hadden geleerd van de data bij het classificeren van volwassenen en oudere volwassenen, met behulp van XAI. De resultaten lieten zien dat het accelerometrie signaal tijdens de late zwaai fase tot aan het neerzetten van de voet binnen een loopcyclus, met name het moment rond het hielcontact, het meest bijdroeg aan het classificatieproces. Deze bevindingen suggereren dat DL verschillende versnellings- en vertragingsspatronen identificeert die het looppatroon van oudere volwassenen onderscheidt van dat van volwassenen. Daarnaast toont het onderzoek aan dat variaties in versnelling en vertraging binnen enkele schrede voldoende is voor CNN om te classificeren (met een AUC van 0,89). Recurrent Neural Network (RNN) methoden, classificeert daarentegen op basis van relaties in versnellings- en vertragingsspatronen over verschillende loopcycli, waarbij een AUC van 0,94 werd bereikt. De resultaten impliceerden dat RNN rekening houdt met dynamische veranderingen over de tijd, die gerelateerd zijn aan de houdingscontrole. Echter, opmerkelijk was dat XAI liet zien dat DL voornamelijk datagegevens in de verticale en anterolaterale richtingen gebruikte voor de classificatie in plaats van datagegevens in de mediolaterale richting, die sterker gerelateerd zijn aan balans.

De inzichten en methodologieën uit deze twee hoofdstukken kunnen gebruikt worden om inzicht te krijgen in het looppatroon van mensen met aandoeningen, zoals rugklachten. Studies naar het looppatroon bij patiënten met chronische lage rugpijn (CLBP) laten tegenstrijdige resultaten zien. Dit komt overeen met het beeld dat er is van van CLBP als een heterogene aandoening. De aanwezigheid van 'human assumed central sensitization' (HACS) in CLBP zou kunnen bijdragen aan deze heterogeniteit. In **hoofdstuk 4** wordt de hypothese getest dat verschillende niveaus van HACS (laag of hoog) gerelateerd zijn aan de looppatronen van patiënten met CLBP, en dat deze verschillen effectief geïdentificeerd kunnen worden met

behulp van CML. Daarnaast zou XAI gebruikt kunnen worden om deze verschillen in looppatronen te interpreteren. Door de accelerometer signalen van één week uit de dagelijkse leefomgeving te analyseren, bevestigden de resultaten, gepresenteerd in dit hoofdstuk, dat patiënten met CLBP en met lage of hoge niveaus van HACS (respectievelijk CLBP- en CLBP+) effectief geclassificeerd konden worden door CML (bijvoorbeeld met Random Forest), met een nauwkeurigheid van 84,4%. XAI liet zien dat patiënten in de CLBP-groep een grotere soepelheid en een betere stabiliteit in loopgedrag vertoonden, terwijl patiënten in de CLBP+ groep een regelmatiger, minder variabel en voorspelbaarder looppatroon vertoonden. Deze bevindingen suggereren dat CLBP- en CLBP+-patiënten mogelijk verschillende motorische controle strategieën aannemen, namelijk "losse controle" en "strakke controle". De "losse controle" strategie, gekenmerkt door verminderde controle over de rompbewegingen, zou de looppatronen in CLBP- kunnen verklaren, terwijl de "strakke controle" strategie, met verbeterde controle over de rompbewegingen, de looppatronen in CLBP+ zou kunnen verklaren. Deze bevindingen benadrukken de noodzaak van een gepersonaliseerde behandeling.

Voortbouwend op de bevindingen uit hoofdstuk 4, onderzocht het in **hoofdstuk 5** beschreven onderzoek de intensiteit van fysieke activiteits patronen bij patiënten met CLBP, gemeten in de dagelijkse omgeving met een draagbare accelerometer gedurende ongeveer één week. Dit onderzoek maakte gebruik van CML zonder gebruik te maken van XAI (Hidden semi-Markov Model, HSMM) om patronen van fysieke activiteit van patiënten met CLBP- en CLBP+ te onderzoeken. Terwijl traditionele methoden die gebruik maken van vooraf ingestelde afkapwaarde van het acceleratiesignaal er niet in slaagden om verschillen in algemene fysieke activiteit intensiteit tussen CLBP- en CLBP+ -groepen statistisch significant vast te stellen, kan HSMM de PAI-patronen vanuit de datagegevens leren. HSMM identificeerde zo verschillende PAI-patronen in deze twee groepen. CLBP- groepen hadden de neiging om taken op te splitsen in kleinere periodes, afgewisseld met frequente en korte rustpauzes. De CLBP+ groep vertoonde langere periodes van activiteit en rust. Fysieke activiteits patronen in de CLBP+ groep kunnen verklaard worden door een persisterende respons patroon, die gekenmerkt wordt door overmatig gebruik van fysieke structuren, ondanks het ervaren van pijn. De fysieke activiteitenpatronen in de CLBP-groep komen mogelijk niet overeen met het angst-vermijdingsrespons patroon, aangezien er geen aanwijzingen waren voor angstovertuiging in deze groep. De inzichten uit hoofdstuk 4 en 5 droegen bij aan een beter begrip van CLBP, beweging en HACS, en maken de weg vrij voor gepersonaliseerde behandelstrategieën in de toekomst.

In de hoofdstukken 4 en 5 werden de lage en hoge niveaus van HACS bepaald met behulp van de Central Sensitization Inventory (CSI) vragenlijst, op basis van een vooraf gedefinieerde afkapwaarde van 40. Er is echter gerapporteerd dat de afkapwaarde voor CSI kan variëren

door zowel verschil in pijnconditie als verschil in culturele en nationale context. Het is opmerkelijk dat er geen universeel geaccepteerde gouden standaard is voor het beoordelen van HACS. Gebaseerd op de patronen en structuren in de datagegevens van mensen met hetzelfde geslacht en dezelfde klinische uitkomsten (vragenlijsten over pijn, fysieke status en psychologische status), was het doel van het in **hoofdstuk 6** beschreven onderzoek om CML zonder toezicht van XAI te gebruiken voor het onderzoeken van HACS-gerelateerde subgroepen binnen patiënten met CLBP. Uit de resultaten werden twee verschillende subgroepen binnen de CLBP-populatie geïdentificeerd. De ene subgroep, die gekenmerkt werd door meer pijn, de grootste invaliditeit, slechtere psychologische status en hogere CSI-waarden, werd toegewezen aan hogere HACS-niveaus, terwijl de andere subgroep lagere HACS-niveaus vertegenwoordigde. Op basis van deze subgroepen werd een nieuwe afkapwaarde van 35 vastgesteld voor de Nederlandstalige populatie met CLBP. De methodologie die in dit hoofdstuk gebruikt werd, gaf nieuw inzicht in het identificeren van HACS-gerelateerde patronen en draagt bij aan het vaststellen van nauwkeurigere afkapwaarden.

**Hoofdstuk 7** geeft een samenvatting van de belangrijkste bevindingen in dit proefschrift en bespreekt mogelijke richtingen voor toekomstig onderzoek. Door het proefschrift als casestudy te gebruiken, worden richtlijnen gegeven voor het selecteren van geschikte AI modellen voor bewegingsanalyse, waarbij de voor- en nadelen worden besproken. Door de potentie van XAI voor de bewegingswetenschappen te onderstrepen, benadrukte dit hoofdstuk de noodzaak van voortdurende verbeteringen om XAI betrouwbaarder, begrijpelijker en gebruiksvriendelijker te maken. Ondanks de erkende beperkingen, toont het hoofdstuk wat de potentie is van AI, met name XAI, voor de (klinische) bewegingsanalyse van verschillende patiëntengroepen. Deze ontwikkeling zal klinische experts en bewegingswetenschappers kunnen ondersteunen in het inzicht krijgen in veranderingen in het bewegingen tijdens dagelijkse activiteiten in verschillende patiëntengroepen.