

ONDERZOEKSRAPPORT

# Pilot cliëntprofielen wijkverpleging

Ontwikkeling van cliëntprofielen in de wijkverpleging



Gertjan Verhoeven, Maud de Korte, Misja Mikkers

Lieuwe van der Weij  
Teanne de Witte-Breure  
Thijs Vietje

Anne van den Bulck  
Arianne Elissen  
Silke Metzelthin  
Dirk Ruwaard

*Dit onderzoek was niet mogelijk geweest zonder de medewerking en tijdsinvestering van de volgende vier zorgorganisaties: Cordaan, Envida, MeanderGroep en Vierstroom Zorg Thuis.*

*In het bijzonder willen we alle wijkverpleegkundigen bedanken voor het werken met de case-mix vragenlijst tijdens de onderzoeksperiode, en hun input tijdens de ontwikkeling van deze lijst.*



*Citeren als:*

*Gertjan Verhoeven, Maud de Korte, Lieuwe van der Weij, Anne van den Bulck, Arianne Elissen, Teanne de Witte-Breure, Thijs Vietje, Silke Metzelthin, Dirk Ruwaard en Misja Mikkers, Onderzoeksrapport Pilot Cliëntprofielen wijkverpleging (2020).*

# Inhoud

<b>Samenvatting</b>	<b>4</b>
<b>1. Onderzoeksaanpak</b>	<b>6</b>
1.1 <i>Waarom dit onderzoek belangrijk is</i>	6
1.2 <i>Aanpak gegevensverzameling</i>	7
1.3 <i>Aanpak voorspelmodellen</i>	11
<b>2. Resultaten</b>	<b>18</b>
2.1 <i>Resultaten gegevensverzameling</i>	18
2.2 <i>Resultaten modellen formele uren</i>	24
2.3 <i>Regressie als alternatieve modelleerstrategie</i>	32
2.4 <i>Resultaten modellen formele + informele uren</i>	33
<b>3. Discussie en conclusie</b>	<b>38</b>
<b>4. Referenties</b>	<b>43</b>
<b>Bijlagen</b>	
Bijlage A: Onderzoeksverantwoording	45
Bijlage B: Extra analyses	55
Bijlage C: Case-mix vragenlijst	62
Bijlage D: Factsheet case-mix vragenlijst	67

# Samenvatting

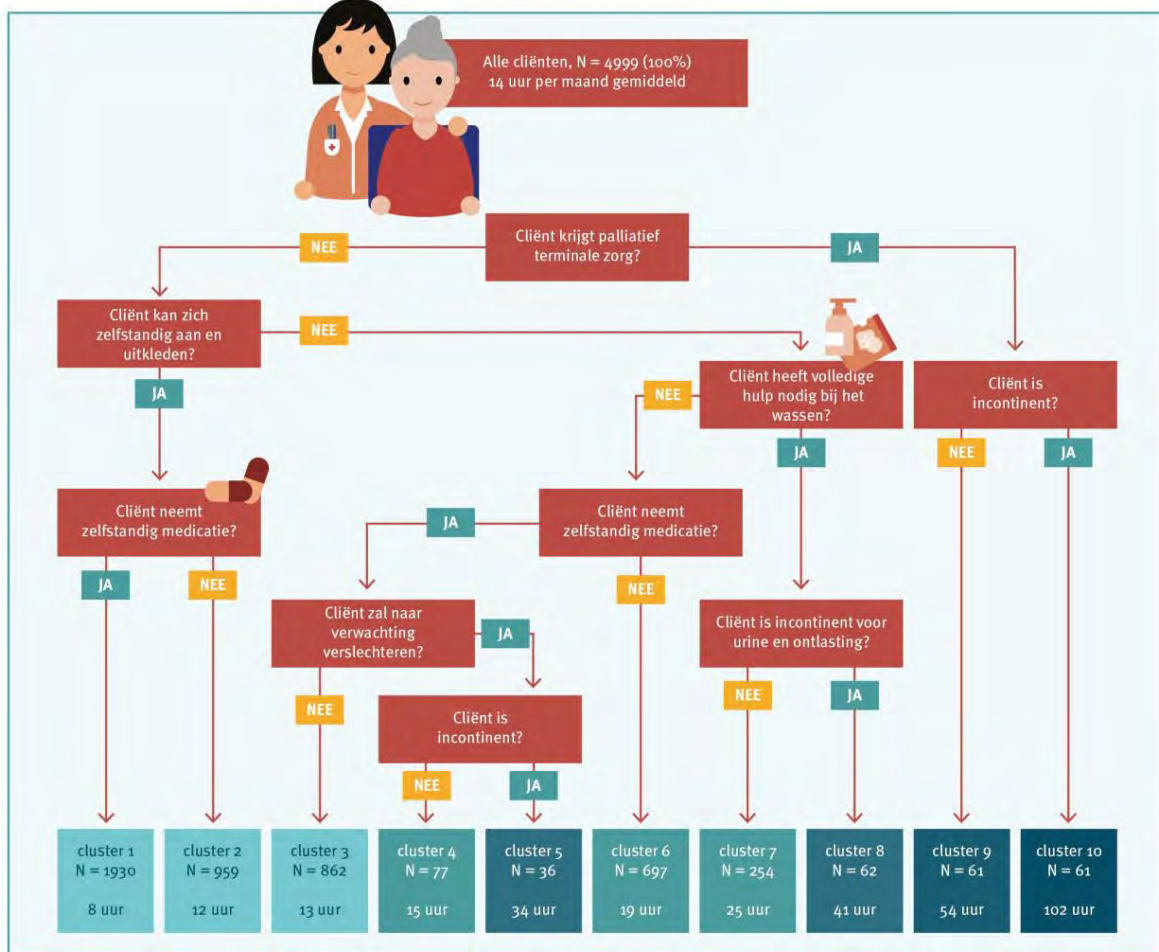
Het ontwikkelen van cliëntprofielen in de wijkverpleging, ook wel case-mix groepen genoemd, is een voorwaarde voor meer innovatieve vormen van bekostiging, zoals vaste bedragen per cliëntprofiel per maand. Inzicht in de zorgvraag en een uniforme classificatie van cliënten is hierbij van belang om risicoselectie tegen te gaan. De verwachting is dat dit helpt om een meer inhoudelijk gesprek te voeren tussen zorgaanbieder en zorgverzekeraar, en dat cliëntkenmerken nodig zijn om inzicht te krijgen in zorguitkomsten op populatieniveau. De ontwikkeling van cliëntprofielen die zowel voldoende voorspellend als voldoende herkenbaar zijn, is geen eenvoudige opgave. Momenteel kennen we al een voorbeeld van cliëntprofielen in de wijkverpleging, namelijk de ZN-doelgroepen (ZN: Zorgverzekeraars Nederland). Deze zijn echter zeer beperkt voorspellend voor zorginzet op maandbasis. Ook blijkt uit eerder onderzoek dat het gebruik van kenmerken uit verpleegkundige classificatiesystemen (NANDA-I en Omaha System, hierna NANDA en Omaha resp.) voor cliëntprofielen nog een groot deel van de variatie in zorginzet onverklaard laat.

Daarom is de NZa vanuit het Wetenschappelijk Programma Wijkverpleging (WPW), samen met de Universiteit Maastricht, begin 2019 een onderzoek bij vier grote zorgaanbieders gestart. Dit onderzoek richt zich op het ontwikkelen van cliëntprofielen in de wijkverpleging op basis van een uniform toepasbaar instrument. De centrale vraag is: kunnen we op basis van een beperkt aantal cliëntkenmerken voorspellen hoeveel zorg een cliënt in een bepaalde periode krijgt? Om dit te onderzoeken is een vragenlijst (de case-mix vragenlijst) opgesteld met vragen over cliëntkenmerken die volgens eerder wetenschappelijk onderzoek voorspellend zijn voor wijkverpleegkundige zorginzet. De deelnemende zorgaanbieders hebben van juni 2019 t/m december 2019 deze extra cliëntkenmerken geregistreerd. Dit heeft geresulteerd in circa 5.500 vragenlijsten ingevuld door 351 wijkverpleegkundigen. Dit rapport bevat de analyse en resultaten van dit onderzoek.

De belangrijkste uitkomst van het onderzoek is dat het mogelijk is om met een korte vragenlijst cliëntprofielen voor wijkverpleging op te stellen met vergelijkbare voorspelkracht ten opzichte van reeds bestaande case-mix modellen voor thuiszorg in andere landen. Dit heeft praktisch potentieel omdat het om een beperkte registratie gaat en onafhankelijk van de verpleegkundige classificatiesystemen gebruikt kan worden, waar een landelijke standaard nog ontbreekt.

De wijkverpleegkundigen die betrokken waren bij het onderzoek geven aan dat zij de inzichten uit de case-mix vragenlijst waardevol vinden, en dat het invullen slechts enkele minuten duurt. Uit dit onderzoek blijkt dat de case-mix vragenlijst met een beperkt aantal vragen een maximale voorspelkracht voor de wijkverpleegkundige zorginzet heeft van 25% (op basis van random forest). Dit is aanzienlijk meer dan de huidige cliëntprofielen in wijkverpleging, de ZN-doelgroepen. Deze kenmerken hebben een voorspelkracht van circa 10%. Op basis van de case-mix vragenlijst vinden we aan de hand van een beslisboom 10 cliëntprofielen met een voorspelkracht van 21%. De toeleiding naar deze cliëntprofielen is in onderstaande beslisboom weergegeven.

### Beslisboom cliëntprofielen



We zien dat net als in het Nieuw-Zeelands model, het model vooral arbeidsintensieve elementen als hulp met wassen, hulp met kleden, etc. selecteert. Kenmerken uit de ZN-doelgroepen worden niet geselecteerd door het CART-algoritme. Wanneer we Omaha- of NANDA-kenmerken uit de anamnese of het zorgplan toevoegen, zien we slechts een beperkte toename in de voorspelkracht. De gevonden cliëntprofielen zijn enkel gebaseerd op de case-mix vragenlijst, wat het mogelijk maakt om los van systemen als Omaha en NANDA op uniforme wijze een cliënttypering te hanteren.

# 1. Onderzoeksaanpak

## 1.1 Waarom dit onderzoek belangrijk is

Het ontwikkelen van cliëntprofielen in de wijkverpleging, ook wel case-mix groepen genoemd, is een voorwaarde voor meer innovatieve vormen van bekostiging, zoals vaste bedragen per cliëntprofiel per maand. Inzicht in de zorgvraag en een uniforme classificatie van cliënten is hierbij van belang om risicoselectie tegen te gaan. Ook helpt dit inzicht om een beter gericht en meer inhoudelijk gesprek te voeren tussen zorgaanbieder en zorgverzekeraar. Cliëntkenmerken zijn daarnaast nodig om inzicht te krijgen in zorguitkomsten op populatieniveau. Momenteel kennen we al een voorbeeld van cliëntprofielen in de wijkverpleging, namelijk de ZN-doelgroepen [1,2]. Een voorbeeld van de ZN-doelgroepen is de groep 'Zorg aan kwetsbare ouderen en/of chronisch zieken, die naar verwachting korter dan 3 maanden duurt'. Deze zijn echter zeer beperkt voorspellend voor zorginzet.

Het ontwikkelen van cliëntprofielen in de wijkverpleging die – op landelijk niveau – zowel voldoende voorspellend als voldoende herkenbaar zijn, is geen eenvoudige opgave. Uit eerder onderzoek blijkt dat wanneer enkel de kenmerken vanuit de verpleegkundige classificatiesystemen (NANDA en Omaha) worden gebruikt, een groot deel van de variatie in zorginzet onverklaard blijft [3]. Uit een systematische review weten we wel dat er andere landen zijn (o.a. in Duitsland, Verenigde Staten en Nieuw-Zeeland) die een case-mix model gebruiken om zorg thuis te voorspellen en prospectief te bekostigen [4].

De NZa heeft daarom vanuit het Wetenschappelijk Programma Wijkverpleging (WPW)<sup>1</sup> samen met de Universiteit Maastricht een pilot opgezet waarin bij vier zorgaanbieders van wijkverpleging aanvullende cliëntkenmerken worden verzameld. Met deze gegevens is vervolgens onderzocht of het lukt om cliëntprofielen met een hoge voorspellende waarde voor inzet van wijkverpleging te ontwikkelen. Dit rapport beschrijft de aanpak en resultaten van deze pilot.

---

<sup>1</sup> Het WPW is een samenwerkingsverband tussen de Universiteit/Hogeschool Utrecht, de Universiteit Maastricht, de Universiteit Tilburg en de Nederlandse Zorgautoriteit.

## 1.2 Aanpak gegevensverzameling

De pilot draait om de registratie van extra cliëntkenmerken, aanvullend op de kenmerken uit de classificatiesystemen (Omaha of NANDA) die de zorgaanbieders gebruiken. De registratie van de extra cliëntkenmerken verloopt via een vragenlijst die wijkverpleegkundigen invullen voor hun cliënten. De pilot liep van juni 2019 t/m december 2019 bij vier zorgaanbieders uit verschillende regio's in Nederland.

De betrokken zorgaanbieders zijn de volgende:

- Cordaan (regio Amsterdam e.o.)
- Envida (regio Maastricht e.o.)
- MeanderGroep (regio Parkstad Limburg e.o.)
- Vierstroom Zorg Thuis (regio Zoetermeer, Midden Holland, Utrecht West)

De omvang van de pilot is bewust beperkt gehouden tot een viertal grotere zorgaanbieders. Hierdoor was er veel ruimte om de inzichten uit de data met deelnemende zorgaanbieders te bespreken en hierop feedback te ontvangen. Ook de gegevensverzameling uit de elektronische cliënten dossiers (ECD's) was hierdoor goed uitvoerbaar met de beschikbare middelen. Hoewel de vier betrokken zorgaanbieders grote zorgaanbieders zijn met veel verschillende typen cliënten in zorg, is het zorgaanbod in de wijkverpleging divers. Mogelijk generaliseren de bevindingen minder goed naar andersoortige organisaties (bijv. specialistische zorgaanbieders voor specifieke doelgroepen).

In dit hoofdstuk beschrijven we de onderzoeksaanpak op hoofdlijnen. De aanpak is in figuur 1 weergegeven als flowchart. De pijlen terug in de figuur geven aan dat veel stappen in de aanpak een iteratief proces volgen. In de gegevensaanlevering kan bijvoorbeeld iets ontbreken of het kan voorkomen dat de zorgaanbieders bepaalde kengetallen niet herkennen. In het iteratieve proces signaleren we dit en zoeken we dit uit, en vervolgens passen we de gegevensaanlevering hierop aan. Dit proces herhaalt zich tot er voldoende vertrouwen is in de kwaliteit en betrouwbaarheid van de data.

**Figuur 1: Onderzoeksaanpak**



## 1.2.1 Case-mix vragenlijst

In de pilot vullen wijkverpleegkundigen na het indicatiegesprek (of na de herindicatie) naast de gebruikelijke gegevens een vragenlijst in met kenmerken van hun cliënten (hierna: de case-mix vragenlijst). De vragenlijst is door een ECD-specialist ingebouwd in het ECD van de vier zorgaanbieders. De vragenlijst is ontwikkeld door de Universiteit Maastricht en bevat vragen over cliëntkenmerken die volgens eerder wetenschappelijk onderzoek [4,5] belangrijke voorspellers zijn voor wijkverpleegkundige zorg. Om de registratielast beperkt te houden, zijn in de vragenlijst alleen cliëntkenmerken opgenomen die (volgens wijkverpleegkundigen) niet op een gestandaardiseerde manier in de ECD's worden geregistreerd.

Dit heeft uiteindelijk geleid tot een vragenlijst die bestaat uit elf vragen die betrekking hebben op vier domeinen:

- het verwachte verloop;
- fysiek functioneren/functionele zelfredzaamheid (ADL/IADL);
- cognitief functioneren;
- sociale steun.

De vragenlijst met gedetailleerde instructie en beschrijving van de antwoordopties zoals deze in de pilot geïmplementeerd is, is opgenomen in bijlage C. Ook een factsheet met aanvullende informatie over de inhoud en ontwikkeling van de vragenlijst is opgenomen (zie bijlage D). De vragen en antwoordopties in het kort zijn weergegeven in tabel 1.

**Tabel 1: Items uit de case-mix vragenlijst**

**Domein: het verwachte verloop (afkorting in rapport: Verloop)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Verwachte verloop (in de komende maand)	<ol style="list-style-type: none"><li>1. Verbeteren</li><li>2. Stabiel</li><li>3. Instabiel</li><li>4. Verslechteren</li><li>5. Palliatief</li></ol>	Verloop

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Maaltijd)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Maaltijd bereiden	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Maaltijd

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Voeden)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Eten en drinken	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Voedend

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Continentie)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Continentie	<ol style="list-style-type: none"><li>1. Volledig continent</li><li>2. Incontinent voor urine</li><li>3. Incontinent voor ontlasting</li><li>4. Incontinent voor urine en ontlasting</li></ol>	Continentie



**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Toiletbezoek)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Gebruik maken van het toilet	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Toiletbezoek

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Mobiliteit)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Opstaan en verplaatsen	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Mobiliteit

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Kleden)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Aan- en uitkleden	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Kleden

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Wassen)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Wassen en douchen	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Wassen

**Domein: fysiek functioneren/functionele zelfredzaamheid (afkorting in rapport: Medicatiegebruik)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Innemen van medicatie	<ol style="list-style-type: none"><li>1. Geen medicatie</li><li>2. Zelfstandig</li><li>3. Gedeeltelijk hulp nodig</li><li>4. Volledig afhankelijk</li></ol>	Medicatiegebruik

**Domein: cognitief functioneren (afkorting in rapport: Cognitie)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Cognitieve vaardigheden voor de dagelijkse besluitvorming	<ol style="list-style-type: none"><li>1. Zelfstandig</li><li>2. Gedeeltelijk hulp nodig</li><li>3. Volledig afhankelijk</li></ol>	Cognitie

**Domein: sociale steun (afkorting in rapport: Mantelzorger)**

Vraagstelling	Antwoordopties	Afkorting in rapport
Cognitieve vaardigheden voor de dagelijkse besluitvorming	<ol style="list-style-type: none"><li>1. Geen mantelzorg</li><li>2. Mantelzorg</li><li>3. Mantelzorg met risico op overbelasting mantelzorger</li><li>4. Overbelaste mantelzorger</li></ol>	Mantelzorger

In de vragenlijst wordt gevraagd of de cliënt *zelf* in staat is om bepaalde activiteiten uit te voeren. Als een cliënt hulp nodig heeft bij een activiteit kan deze hulp krijgen in de vorm van mantelzorg door bijvoorbeeld de partner – hierna informele uren genoemd –, of professionele zorg door de wijkverpleging – hierna formele uren genoemd. De formele uren zorg komen uit de ECD's van de zorgaanbieders. Daarnaast hebben we de wijkverpleegkundigen gevraagd om het aantal uren informele zorg<sup>2</sup> in te schatten. Het gaat hierbij om een schatting van het aantal uren informele zorg in de afgelopen week. Dat wil zeggen in de week vóór het invullen van de case-mix vragenlijst.

Op dit moment onderzoekt de Universiteit Maastricht de inter-beoordelaars kwaliteit (inter-rater reliability (IRR)) van de vragenlijst. Dit wordt gedaan met wijkverpleegkundigen bij twee van de zorgaanbieders die deelnemen aan de pilot. De resultaten hiervan kunnen worden gebruikt voor doorontwikkeling van de vragenlijst, bijvoorbeeld door de formulering van vragen of antwoordopties aan te passen. Dergelijke aanscherping van de vragenlijst kan de voorspellende waarde verder verbeteren. In verband met COVID-19 ligt de dataverzameling op dit moment stil. De definitieve robuustheid van de vragen zal pas na voortzetting van het onderzoek vastgesteld kunnen worden. De eerste bevindingen wijzen uit dat het merendeel van de vragen eenduidig worden geïnterpreteerd door wijkverpleegkundigen. De vraag over maaltijd bereiden blijkt op basis van deze bevindingen verschillend geïnterpreteerd te kunnen worden. Om deze reden is deze vraag **buiten beschouwing gelaten in de analyses in de hoofdtekst. In bijlage B 'Extra analyses' worden de resultaten getoond als we deze vraag wel meenemen.**

### 1.2.2 Gegevensverzameling en privacy

#### **Gegevensverzameling**

In de afgelopen periode hebben meerdere gegevensleveringen plaatsgevonden. De leveringen waarop dit rapport is gebaseerd, hebben eind april 2020 plaatsgevonden en omvatten de periode juni 2019 t/m maart 2020.

De gegevens leveringen bevatten naast de cliëntkenmerken uit de case-mix vragenlijst ook de volgende informatie:

- kenmerken uit de verpleegkundige anamneses (NANDA / Omaha)
- kenmerken uit de zorgplannen (NANDA / Omaha)
- ZN-doelgroepen registratie
- demografische kenmerken zoals leeftijd en geslacht
- geregistreerde geleverde uren zorg

Twee zorgaanbieders in de pilot werken met NANDA, de andere twee zorgaanbieders met Omaha.

Bij ieder van de vier deelnemende zorgaanbieders is een wijkverpleegkundige aangewezen als contactpersoon voor de pilot. Met deze persoon werd onder andere afgestemd wat per zorgaanbieder de gewenste wijze was om wijkverpleegkundigen in de organisatie te informeren en motiveren. Zo is bij de ene zorgaanbieder een presentatie gehouden door de NZa en Universiteit Maastricht in een bijeenkomst met alle wijkverpleegkundigen.

---

<sup>2</sup> Mantelzorg wordt hierbij conform onderzoek binnen het Nationaal Programma Ouderenzorg gedefinieerd als 'zorg die mensen vrijwillig en onbetaald verlenen aan een naaste met fysieke, verstandelijke of psychische beperkingen. Het gaat om zorg die meer is dan in een persoonlijke relatie gebruikelijk is: hiervan is sprake indien het taken betreft die de zorgvrager bij normale gezondheid zelf had gedaan (bijv. huishoudelijke taken, persoonlijke verzorging) of bij normale gezondheid niet nodig waren geweest (bijv. fysieke begeleiding, regievoering, verpleging)'

Bij een andere zorgaanbieder werd het passender gevonden om de wijkverpleegkundigen te informeren met een regelmatig terugkerende nieuwsbrief, waarin ook de vorderingen werden teruggekoppeld met betrekking tot het aantal ingevulde vragenlijsten.

#### *Ophalen van kwalitatieve informatie via bijeenkomsten*

We hebben met elk van de vier zorgaanbieders twee bijeenkomsten gehad met de onderzoekers van de NZa, Universiteit Maastricht en o.a. wijkverpleegkundigen en leidinggevenden. Tijdens de eerste ronde van bijeenkomsten lag de focus op het werken met de vragenlijst en op de kwaliteit en betekenis van de aangeleverde data. Tijdens de tweede ronde bijeenkomsten lag de focus op de uit de data afgeleide beslisbomen en de cliëntkenmerken die hierbij een rol spelen. Ook is de respons (niet voor elke nieuwe cliënt is een case-mix vragenlijst ingevuld) besproken.

#### *Privacy van cliënten*

In dit onderzoek wordt gewerkt met privacy gevoelige data, zogeheten persoonsgegevens. De NZa heeft conform de Wmg een wettelijke taak om bekostigingssystemen te ontwikkelen, en de bevoegdheid om hiertoe onder voorwaarden persoonsgegevens te verzamelen. Er zijn in dit onderzoek geen persoonsgegevens verzameld die direct herleidbaar zijn naar de cliënt (zoals namen of BSN nummers). De zorgaanbieders zijn gehouden aan de Algemene Verordening Gegevensbescherming (AVG), waarbij ze onder meer verplicht zijn hun cliënten te informeren over de verwerking van persoonsgegevens. In de communicatie richting de cliënten hebben de vier zorgaanbieders zelfstandig keuzes gemaakt, waarbij de AVG in acht is genomen. De NZa heeft de zorgaanbieders hierbij gefaciliteerd. Zo is er een voorbeeldbrief gemaakt om de cliënten te informeren over het onderzoek. Ook is er door de NZa in de gegevensverzameling een technische mogelijkheid gecreëerd in het ECD om cliënten te registreren die afzagen van deelname aan het **onderzoek ('opt out')**. **Gegevens van deze cliënten zijn niet doorgeleverd aan de NZa. De gegevens zijn door de zorgaanbieders aangeleverd aan een versleuteld aanleverportaal van de NZa.**

#### *Geen impact op cliënten verwacht*

Omdat de vragenlijst wordt ingevuld door de wijkverpleegkundige nadat de gebruikelijke anamnese heeft plaats gevonden, verwachten we dat dit onderzoek geen effect heeft op de cliënt. Dit onderzoek is door een Medisch Ethische Toetsingscommissie getoetst. Bij deze toets wordt gekeken of het om medisch-wetenschappelijk onderzoek gaat, én of personen aan handelingen worden onderworpen of gedragsregels worden opgelegd. Volgens de METC was hiervan geen sprake (METC nummer 2019-1144).

### **1.3 Aanpak voorspelmodellen**

Bij dit onderzoek is een vooraf opgesteld studieprotocol gevolgd. Het studieprotocol is onlangs gepubliceerd in een internationaal wetenschappelijk tijdschrift en openbaar beschikbaar [6]. We presenteren in dit rapport de resultaten van de pilot op hoofdlijnen zoals deze tot nu toe zijn behaald. De definitieve resultaten van de analyses conform studieprotocol zullen ter publicatie worden aangeboden aan een wetenschappelijk tijdschrift. Dit is gepland voor de tweede helft van 2020. **In bijlage A 'Onderzoeksverantwoording' worden de analyses in dit rapport vergeleken met de geplande analyses beschreven in het studieprotocol.** Om inzicht te geven in de werking van de data analyse **code is deze als "open source repository" beschikbaar gemaakt** op GitHub ([https://github.com/nzanl/pilot\\_clientprofielen\\_wijkverpleging\\_2020](https://github.com/nzanl/pilot_clientprofielen_wijkverpleging_2020)). De werking van de code wordt daar gedemonstreerd aan de hand van een publiek beschikbare dataset over zorgpolissen.

### 1.3.1 Aanpak analyses voorspelkracht

#### **Over de te voorspellen zorginzet**

De insteek van dit onderzoek is om op basis van cliëntkenmerken groepen te onderscheiden die voorspellend zijn voor de kosten van de benodigde hoeveelheid wijkverpleegkundige zorg in de (nabije) toekomst. Met 'voorspellend' wordt bedoeld dat kenmerken van een cliënt informatie bevatten over het toekomstige zorggebruik van deze cliënt. Stel dat we helemaal niets zouden weten van een cliënt, maar we kennen wel de landelijke verdeling van zorggebruik. Met onze voorspelling willen we zo dicht mogelijk bij het werkelijke zorggebruik van deze cliënt in de buurt komen. In dat geval kunnen we het niet beter doen dan het gemiddelde voorspellen (als de data normaal verdeeld is) of de mediaan (als de data scheef verdeeld is). Als er echter een kenmerk is waar een andere verdeling voor geldt dan voor het totaal aan cliënten, dan noemen we dit kenmerk onderscheidend, en heeft dit kenmerk voorspellende waarde. Dit betekent dus niet dat het kenmerk 'perfect' voorspelt; het betekent dat de voorspellingen beter worden dan wanneer we de informatie van dit kenmerk niet zouden gebruiken.

Voor het voorspellen van de zorginzet is als tijdshorizon in dit rapport vier weken gehanteerd. We gebruiken aantal uren zorg als schatting voor kosten. De kosten van personele inzet verschillen afhankelijk van welke disciplinemix nodig is. In **de ECD's van de vier zorgaanbieders worden** diverse functiebenamingen gehanteerd voor de medewerkers die zorg leveren. Deze functiebenamingen hebben we, met hulp van de zorgaanbieders, toegewezen aan vier functieniveaus op basis van (een benadering van) het deskundigheidsniveau. We kennen een relatieve weegfactor toe aan elk functieniveau om recht te doen aan de kostenverschillen tussen de functieniveaus. Dit baseren we op een gemiddelde kostprijs per deskundigheidsniveau. De bron hiervoor wordt gevormd door het onderzoeksrapport ten behoeve van tariefherijking door PwC uit 2017 [7]. Tabel 2 geeft de weegfactor per functieniveau weer, inclusief een aantal voorbeelden van welke functiebenamingen aan welk functieniveau zijn toegewezen.

**Tabel 2: Weegfactoren per functieniveau**

Voorbeelden van functiebenamingen uit ECD	Functieniveau	Weegfactor
Helpende Thuishulp	Care assistant	0,86
Verzorgende IG Verzorgende Verzorgende plus	Certified nursing assistant (EQF 3)	1,00
Verpleegkundige in de wijk Verpleegkundige Niveau 4	Registered nurse (MBO, EQF 4)	1,22
Wijkverpleegkundige Casemanager dementie Wondverpleegkundige	Registered nurse (HBO, EQF 5/6)	1,54

#### **Formele en informele zorginzet**

In de analyses wordt de informele zorginzet op twee manieren geanalyseerd. In de modellen waarin we gewogen formele zorginzet willen voorspellen, rekenen we een variant door waarin we informele uren zorg meenemen als voorspeller. Daarnaast laten we modellen zien waarin we de gewogen optelsom van formele en informele zorginzet voorspellen. Hierin nemen we de informele zorg dus mee als uitkomstmaat. Hoewel we geïnteresseerd zijn in een case-mix model voor formele zorginzet, kunnen deze analyses bijdragen aan begrip van welke kenmerken voorspellend zijn voor het geheel aan zorginzet.


### Weging uren informele zorg

In het onderzoek nemen we voor het geschatte aantal uren informele zorg aan dat deze uren ook nog in de vier weken na het invullen van de case-mix vragenlijst zijn gegeven. Als voor een cliënt bijvoorbeeld 7 uur informele zorg is geschat, wordt in de analyse vier maal 7 uren informele zorg aangenomen. In de modellen waar we de gewogen optelsom van formele en informele zorginzet voorspellen, zijn de informele uren zorg gewogen met een factor 0,5 vanwege het verschil in productiviteit tussen formele en informele zorgverlening. Hier is aangesloten bij de wetenschappelijke literatuur, zie voor details het studieprotocol [6].

### Verwachte relatie formele en informele zorg

Wat verwachten we voor de relatie tussen het aantal formele uren zorg en het aantal informele uren zorg dat een cliënt krijgt? Hier is het belangrijk om te beginnen bij het proces dat uiteindelijk de data genereert. Een simpel causaal model is weergegeven in figuur 2. Dit model is niet uit de data af te leiden. We hebben een model nodig om de juiste conclusies uit de data te kunnen trekken [8].

**Figuur 2: Simpel causaal model mantelzorg en formele zorg**



Uitgangspunt is de zorgvraag van de cliënt. Deze zorgvraag kan, afhankelijk van de soort en omvang van de zorgvraag, zowel door een mantelzorger (indien aanwezig) als door de wijkverpleging worden ingevuld. Er zijn daarom pijlen van zorgvraag naar inzet formele zorg, en van zorgvraag naar inzet mantelzorg. Als de zorgvraag groot is, zal er veel formele zorg, maar wellicht ook veel informele zorg geleverd (kunnen) worden. In dit geval zijn het complementen (positieve correlatie).

Ook zijn er pijlen getekend tussen de inzet van formele zorg en inzet mantelzorg. Dit geeft de volgende mechanismen weer:

- Als de mantelzorger(s) van de cliënt veel zelf willen en kunnen doen, is er minder formele zorg nodig. In dit geval zijn het substituten (negatieve correlatie).
- Als de formele zorg niet volledig kan worden ingevuld (bijv. door (tijdelijk) onvoldoende beschikbaarheid van wijkverpleging), kan het zijn dat er meer zorg door naasten zal worden verleend dan wanneer er wel voldoende capaciteit zou zijn.

Tenslotte heeft er selectie op inzet van formele zorg plaats gevonden: onze dataset bevat alleen cliënten die een indicatie of herindicatie voor wijkverpleging hebben ontvangen, en in de vier weken erna formele zorg hebben ontvangen. Om ons hieraan te herinneren geven we dit weer met een selectievak 'S'.

Wat verwachten we nu voor de relatie tussen het aantal formele uren zorg en het aantal informele uren zorg dat een cliënt krijgt *in onze dataset*? Op basis van het causale model verwachten we dat als we een voorspelmodel hebben voor de uren formele zorg, en we gebruiken de cliëntkenmerken van de case-mix vragenlijst als voorspellers, dat het aantal uur informele zorg bijdraagt aan het voorspellen van de formele uren zorg.

#### *Toegevoegde waarde van groepen voorspellers*

Net als in de eerder **uitgebrachte rapportage 'Data-analyses met betrekking tot cliëntprofielen in de wijkverpleging' [9]** en de **analyses in de studie van de Korte et al. (2020) [3]** brengen we de voorspelkracht van groepen van cliëntkenmerken uit verschillende bronnen (o.a. de case-mix vragenlijst, verpleegkundige classificatiesystemen en ZN-doelgroepen) in kaart. Op deze manier krijgen we een globaal beeld van hoeveel voorspelkracht de verschillende bronnen van cliëntkenmerken bevatten. Omdat cliëntkenmerken uit de verschillende bronnen elkaar deels kunnen overlappen, kijken we in hoeverre informatiebronnen elkaar vervangen dan wel aanvullen.

Hierbij nemen we de case-mix vragenlijst als vertrekpunt. Dit doen we omdat deze vragenlijst los staat van de verschillende verpleegkundige classificatie systemen, die in Nederland op dit moment naast elkaar gebruikt worden (Omaha, NANDA en InterRAI / NedRAI zijn de drie bekendste voor verpleegkundige diagnoses). Analyses waarbij Omaha- of NANDA-kenmerken zijn gebruikt zijn opgenomen in bijlage B. Hierbij kijken we in hoeverre Omaha of NANDA voorspelkracht toevoegt t.o.v. de case-mix vragenlijst.

We nemen de ZN-doelgroepen op als referentie, omdat deze op dit moment de enige andere cliëntprofielen zijn die in de wijkverpleging in Nederland op grote schaal geregistreerd worden. Het is daarom beleidsmatig van belang te weten in hoeverre de case-mix vragenlijst de ZN-doelgroepen kan aanvullen of vervangen.

### 1.3.2 Van ruwe data naar onderzoeksbestand voor modellering

Voor het bouwen van de modellen moet een onderzoeksbestand worden gemaakt met de te voorspellen variabelen (gewogen uren formele en informele zorg als afhankelijke variabelen) en de beschikbare cliëntkenmerken als voorspellers (onafhankelijke variabelen).

We hebben de verzameling ingevulde case-mix vragenlijsten als startpunt genomen. Aan elke gescoorde vragenlijst moeten vervolgens geleverde uren zorg en kenmerken uit de verpleegkundige classificatiesystemen (NANDA en Omaha) gekoppeld worden. In bijlage A '**Onderzoeksverantwoording' beschrijven** we de details van dit proces, en de impactanalyses van bepaalde keuzes op de omvang van het onderzoeksbestand en de voorspelkracht.

### 1.3.3 Gebruik van verschillende algoritmes

Met een case-mix model bedoelen we een verzameling rekenregels waarmee we voor een cliënt een voorspelling kunnen doen voor het te verwachten aantal uren zorg, gegeven de kenmerken van deze cliënt. Vanwege de beleidsmatige en praktische wens tot een beperkt aantal **cliëntprofielen, gebruiken we primair het 'CART decision tree' algoritme [9]**. Hiermee worden cliënten via een beslisboom eenduidig aan cliëntprofielen toegewezen. Naast het maken van beslisbomen met behulp van het CART-algoritme gebruiken we ook een machine learning techniek

die 'random forest' heet [10]. Op basis van dit algoritme leren we wat er maximaal haalbaar is qua voorspelkracht en hoe ver het CART-algoritme hier vanaf zit. Dit geeft informatie over in hoeverre een 'simpele' beslisboom in staat is om het volledige potentieel aan voorspelkracht in de cliëntkenmerken te evenaren. Door het toepassen van de algoritmes op de data bouwen we voorspelmodellen. Deze voorspelmodellen kunnen we vervolgens karakteriseren: welke cliëntkenmerken zijn geselecteerd, hoe vergelijken de modellen op voorspelkracht, op complexiteit, etc.

### Cross-validatie

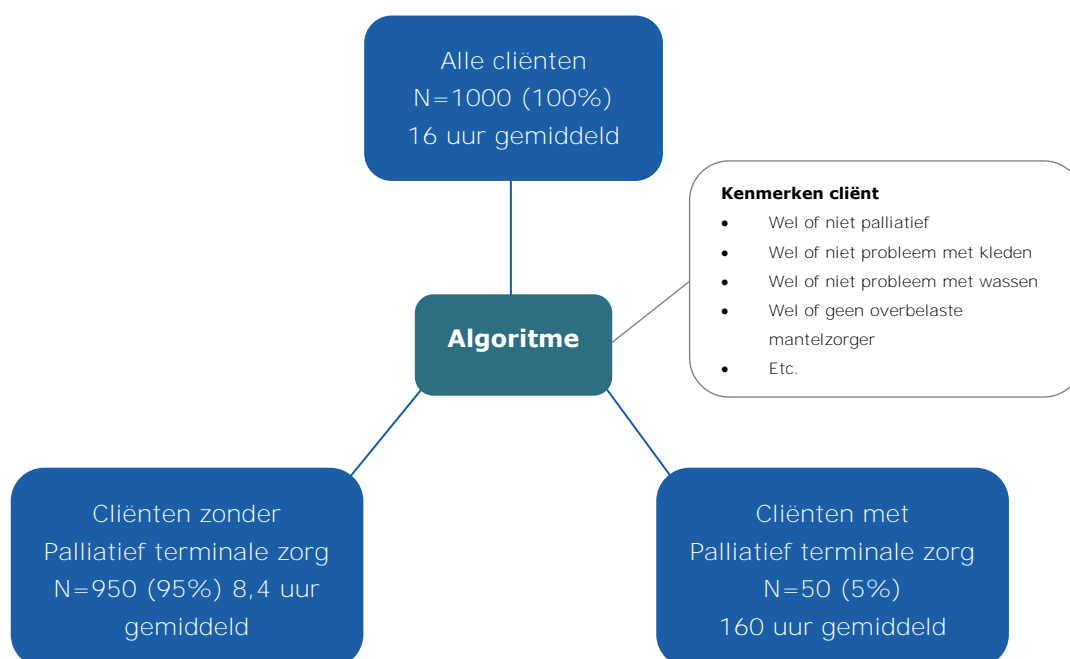
Het bouwen van de modellen doen we met het 'caret' package in R [11]. Dit package bevat een uniforme interface om de genoemde algoritmes uit te voeren. Voor elk model passen we via caret cross-validatie toe. Cross-validatie is een techniek om de prestatie van de modellen op *testdata* te bepalen. Dat wil zeggen: data die niet gebruikt is voor het fitten van de modellen. Dit geeft een realistischer beeld van de werkelijke voorspelkracht dan als we de prestatie zouden bepalen op basis van de data die ook gebruikt is voor het 'ontwerpen' van het model. Cross-validatie houdt in houdt in dat we onze data in stukken opdelen ('folds'), en telkens een ander deel van de data wordt gebruikt als testset. Wij passen '10-fold cross-validatie' toe wat betekent dat steeds 9 delen van de data worden gebruikt om het model te fitten (dit is de trainingsdata), en vervolgens één deel van de data om de voorspelkracht van het model te bepalen (dit is de testdata). Dit proces wordt vervolgens een aantal keer herhaald, en het resultaat gemiddeld.

### 1.3.4 Uitleg gebruikte algoritmes

#### CART decision tree algoritme

In figuur 3 laten we in een fictief voorbeeld zien hoe de beslisbomen gemaakt worden. We gebruiken het CART-algoritme om de data stapsgewijs te splitsen in groepen cliënten die steeds homogener worden qua uren zorg (de spreiding in uren binnen een groep neemt daarbij telkens af). Hierbij loopt het algoritme alle kenmerken af en kiest het kenmerk dat de totale spreiding in de twee gesplitste subgroepen het meest af doet nemen.

**Figuur 3: Fictief voorbeeld van een beslisboom**



In het voorbeeld wordt een groep van 1000 cliënten gesplitst op het kenmerk 'palliatief terminale zorg' in twee subgroepen. De subgroep met dit kenmerk krijgt gemiddeld veel uren zorg per maand (160 uur in het voorbeeld), de subgroep zonder dit kenmerk krijgt gemiddeld weinig uren zorg (8.4 uur in het voorbeeld). De totale spreiding in uren zorg is hierdoor afgenomen. Omdat de spreiding afneemt, heeft het model voorspellende waarde.

Dit proces van splitsen gaat door totdat het splitsen niet meer leidt tot een vermindering in spreiding. Merk op dat er automatisch een selectie van kenmerken plaatsvindt: alleen de kenmerken die gekozen zijn om op te splitsen, zijn nodig voor het afleiden naar de cliëntprofielen. In de praktijk moeten we voor het maken van een beslisboom verschillende keuzes maken, bijvoorbeeld wanneer het splitsen moet stoppen. Hier hebben we gekozen dat het splitsen van de data stopt zodra een splitsing leidt tot een cliëntprofiel met minder dan 30 cliënten.

Een ander voorbeeld van een keuze is de zogeheten 'prune' stap. Hierbij wordt de volgroeide beslisboom 'teruggesnoeid' totdat deze de beste voorspelkracht heeft op de *testdata*, dus op data die niet is gebruikt voor het creëren van de beslisboom. Vaak kun je de beslisbomen nog wat verder terugsnijden waardoor de beslisboom simpeler wordt en de voorspelkracht nauwelijks slechter. Hiervoor zijn de belangrijkste keuzes welke maat voor de voorspelkracht wordt gebruikt en de mate van 'tolerantie' voor het accepteren van het meest compacte model (minste splitsingen) dat een bepaald percentage (de tolerantie) slechter is dan het beste model. Bij het terugsnijden hebben we gekozen voor de mean absolute error (MAE) als maat voor de voorspelkracht (de modelselectie wordt daardoor minder gevoelig voor observaties met heel hoge uren), en het tolerantie percentage is 1.5%.

#### ***Random forest: black box machine learning als benchmark voor voorspelkracht***

Random forest combineert honderden beslisbomen die elk gebaseerd zijn op een verschillende set van observaties en verschillende set van voorspellende kenmerken. Voor de uiteindelijke voorspellingen door de random forest worden de voorspellingen van elke beslisboom gemiddeld. Het random forest algoritme wordt hierom ook wel 'black box' genoemd omdat elke voorspelling een gemiddelde is van een groot aantal (200 – 500) verschillende beslisbomen, en het hierdoor dus minder goed uitlegbaar is. Door de voorspelkracht van random forest met CART te vergelijken krijgen we inzicht in hoeveel voorspelkracht er verloren gaat door een simpel model te gebruiken.

#### ***Compact en eenduidig meetbaar***

Verschiedende beslisbomen kunnen soortgelijke voorspelkracht hebben. Deze beslisbomen kunnen bijvoorbeeld verschillen in de geselecteerde cliëntkenmerken om op te splitsen, maar ook in het aantal splitsingen en dus het aantal resulterende cliëntprofielen. In het geval van soortgelijke voorspelkracht hebben we een voorkeur voor compacte modellen met eenduidig meetbare vragen. Met compact bedoelen we zo min mogelijk cliëntprofielen, zonder al te veel verlies aan voorspelkracht. Met eenduidig meetbaar bedoelen we vragen die voldoende duidelijk zijn voor wijkverpleegkundigen en andere betrokken partijen.

Een vraag die we op dit moment als minder eenduidig classificeren is de vraag over maaltijd bereiding (op basis van bijeenkomsten met wijkverpleegkundigen en de eerste bevindingen van het onderzoek naar de inter-beoordelaars kwaliteit dat wordt uitgevoerd door de Universiteit Maastricht). Ook de mantelzorger vraag en de geschatte informele uren zorg beoordelen we als minder eenduidig. Deze gegevens worden wel meegenomen in de analyses, aangezien we vermoeden dat informele zorg impact heeft op de formele uren zorg die een cliënt krijgt en daarom informatief zijn.



Maar voor een uiteindelijk case-mix model voor formele zorginzet levert het meenemen van informele zorg kenmerken mogelijk ongewenste prikkelwerking op, bijv. doordat de inzet van informele zorg beïnvloedt wordt door het case-mix model.

#### ***Mogelijke selecties op het onderzoeksbestand***

Bij de praktische toepassing van een case-mix model komt het voor dat er bepaalde in- of exclusie criteria gehanteerd worden [4]. Bijvoorbeeld dat voor cliënten met zeer kortstondige contacten – of cliënten die juist zeer veel zorg uren nodig hebben – aparte afspraken worden gemaakt buiten het case-mix model om. Om de impact van dit soort keuzes te kwantificeren hebben we in de analyses een paar varianten hiervan doorgerekend.

#### **1.3.5 R-kwadraat (R-squared) als maat voor voorspelkracht**

De R-kwadraat is een maat voor hoeveel procent van de variatie in uren 'verklaard / voorspeld' wordt door de kenmerken van de cliënt. Als deze 100% is voor een case-mix model kunnen we, als we weten in welke cliëntprofiel iemand valt (en dus de relevante cliëntkenmerken weten), **exact** voorspellen hoeveel uur zorg iemand zal krijgen. Als deze 0% is, betekent dit dat de cliëntkenmerken geen enkele informatie bevatten over het aantal uren zorg. In dat geval is de beste voorspelling die we kunnen doen het gemiddeld aantal uren wijkverpleging dat cliënten krijgen.

Wat belangrijk is om te realiseren is dat de R-kwadraat een **relatieve** maat is: hij is relatief ten opzichte van de totale spreiding in uren die er is in de data. Vergelijk bijvoorbeeld een situatie waarin alle cliënten tussen de 2,9 en 3,1 uur zorg zouden krijgen, met een situatie waarin cliënten tussen de 0,3 en 300 uur zorg krijgen. Een R-kwadraat van 0% is vanuit reguleringsperspectief veel problematischer in de tweede situatie dan in de eerste.

Naast R-kwadraat gebruiken we ook nog de CPM, MAPE en RMSE als maten voor voorspelkracht. Deze maten (inclusief betekenis van de afkorting) worden toegelicht in bijlage A 'Onderzoeksverantwoording'. **In de hoofdtekst rapporteren we de voorspelkracht uitgedrukt in R-kwadraat. In bijlage B 'Extra analyses' worden de resultaten voor de andere maten gerapporteerd.** Indien we één van deze maten gebruiken om beslissingen te nemen wordt dit duidelijk aangegeven in de tekst.

# 2. Resultaten

## 2.1 Resultaten gegevensverzameling

### 2.1.1 Kwalitatieve resultaten

Naast de kwantitatieve resultaten op basis van de uitgevoerde analyses, hebben we ook kwalitatieve informatie opgehaald tijdens de bijeenkomsten met de deelnemende zorgaanbieders.

In beide rondes van bijeenkomsten kwam naar voren dat de zorgaanbieders de analyses en inzichten uit de pilot heel waardevol en leerzaam vinden. Dit geldt voor de wijkverpleegkundigen, bijvoorbeeld om te zien hoe wordt omgegaan met bepaalde verpleegkundige diagnoses of om verschillen tussen wijken te duiden.

Maar dit geldt ook op managementniveau, bijvoorbeeld om inzicht in het type cliënten binnen de organisatie te verkrijgen voor de gesprekken met verzekeraars. Tegelijkertijd geven de zorgaanbieders aan dat zij zelf hun zorginhoudelijke data, zoals uit NANDA en Omaha, nog te weinig gebruiken om van te leren en verbeteren. Dit geldt ook voor de informatie uit de ZN-doelgroepen registratie.

De belangrijkste bevindingen uit de eerste ronde van bijeenkomsten waren:

- Het werken met de vragenlijst kost niet veel tijd volgens de verpleegkundigen die er mee gewerkt hebben (3-5 minuten).
- Het inschatten van de uren informele zorg is lastig, en kan na de indicatiestelling nog veranderen.
- Er zijn verschillen in hoe indirecte cliëntgebonden tijd in de systemen wordt verwerkt, en of deze tijd in de data-extracten voor het onderzoek belanden. Bij indirect cliëntgebonden tijd kan gedacht worden aan het aanvragen van hulpmiddelen, contact met de huisarts of de gemeente etc. Naar aanleiding van deze signalen hebben we de database queries aangepast, waardoor we nu voldoende vertrouwen hebben dat het overgrote deel van de geleverde uren zorg, ook indirect cliëntgebonden tijd, meegenomen is in de analyses.

- Het aanmaken, bijwerken en definitief maken van het zorgplan, de verpleegkundige diagnoses en de vragenlijst vindt niet gelijktijdig plaats, maar over een periode van enkele dagen tot weken. Dit maakt dat er niet **een enkele datum is waarop de gegevens 'gemeten' zijn, en hier moeten we dus aannames doen.** Zie bijlage A 'Onderzoeksverantwoording' voor details over hoe we dit hebben aangepakt.

De belangrijkste bevindingen uit de tweede ronde van bijeenkomsten waren:

- Het formulier voor de vragenlijst zit op een aparte plek in het systeem. Hier moet je zelf aan denken, en er worden geen herinneringen voor gestuurd.
- **Er kunnen mogelijk verschillen zijn in hoe 'trouw' de verschillende verpleegkundigen de lijst hebben ingevuld.** We hebben voor nu geen reden om te denken dat bepaalde cliëntprofielen minder zijn gescoord dan anderen ('selectiebias').
- De maaltijd- vraag werd verschillend geïnterpreteerd.

### 2.1.2 Beschrijvende resultaten

De pilot liep van juni 2019 tot 1 januari 2020. De uiteindelijke dataset die de vier zorgaanbieders over deze periode hebben aangeleverd bevatte (onder meer) zo'n 5.500 case-mix vragenlijsten ingevuld door 351 wijkverpleegkundigen, circa 3.300 NANDA anamneses, circa 2.100 Omaha anamneses en 4 miljoen records met geregistreerde geleverde uren zorg.


#### *Populatie en steekproef*

We hebben wijkverpleegkundigen gevraagd om de case-mix vragenlijst in te vullen na een indicatiegesprek of herindicatie. Onze populatie is dus het totaal aantal indicaties en herindicaties bij de vier zorgaanbieders in de periode waarin de pilot liep. Omdat indicatiestellingen en herindicaties niet als zodanig in de data zichtbaar zijn, is het moeilijk om de response op het onderzoek precies te kwantificeren. Ondanks dat er een groot aantal vragenlijsten is verzameld, is de respons vermoedelijk niet 100%. In deze rapportage analyseren we de verzamelde data onder de aanname **dat ontbrekende vragenlijsten 'at random' ontbreken.** Dit betekent dat we aannemen dat alle cliënten evenveel kans op een case-mix vragenlijst hadden.

#### *Verdelingen cliëntkenmerken vier zorgaanbieders lijken op elkaar*

We zien een grote overeenkomst in de antwoordverdelingen van de afzonderlijke vragen uit de vragenlijst bij de vier zorgaanbieders. Wanneer we aannemen dat de wijkverpleegkundigen de vragenlijsten **gemiddeld genomen** op dezelfde manier hanteren, volgt de conclusie dat de populaties van de vier deelnemende zorgaanbieders vrij veel op elkaar lijken wat betreft de gemeten kenmerken. In figuur 4 is dit inzichtelijk gemaakt.

**Figuur 4: Verdeling antwoordopties case-mix vragenlijst**



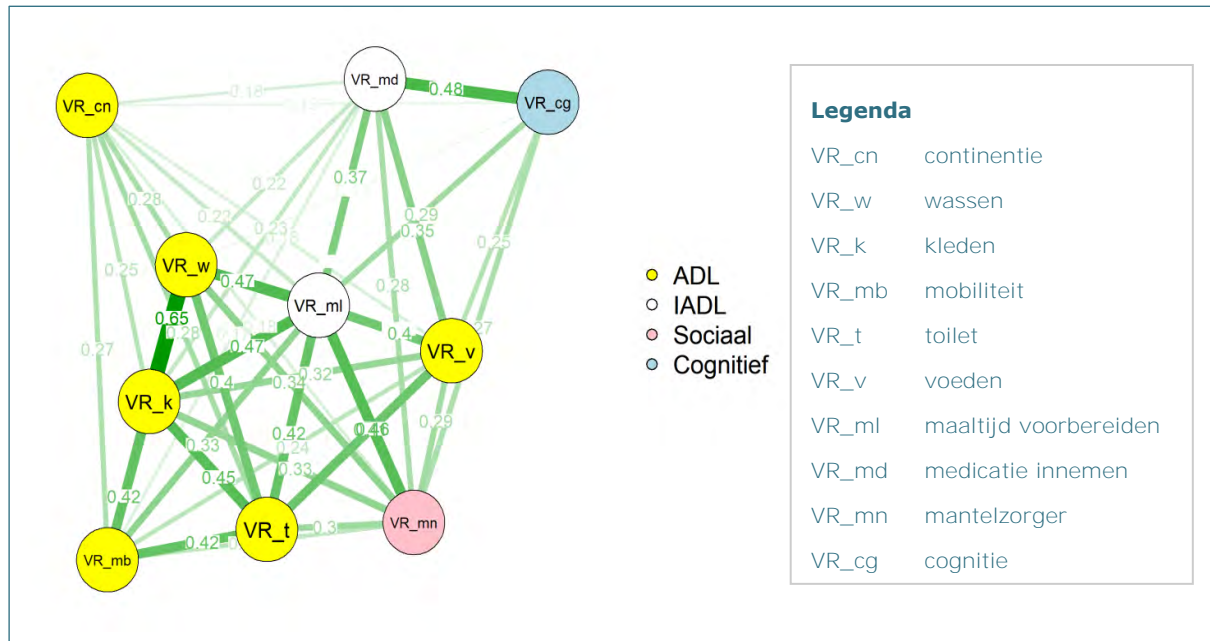
Elke gekleurde lijn stelt een van de vier zorgaanbieders voor. De verdelingen over de verschillende antwoordopties liggen bij elke case-mix vraag dicht bij elkaar. Bij de vraag over het verwachte verloop van de cliënt blijkt dat er een zorgaanbieder is die afwijkt ten aanzien van de eerste twee antwoordopties (de eerste optie is 'verbetering verwacht' en de tweede is 'toestand stabiel'). Als mogelijke verklaring is genoemd dat er bij deze zorgaanbieder sterk werd ingezet op zelfredzaamheid. Deze verklaring is niet verder onderzocht.

**Relaties tussen de kenmerken van de case-mix vragenlijsten**

Door te kijken naar de correlaties tussen de antwoorden op de verschillende vragen krijgen we inzicht in welke kenmerken vaak samen aanwezig zijn bij een cliënt, en welke kenmerken los van elkaar kunnen voorkomen.

Figuur 5 toont de correlaties tussen de case-mix vragen. Door vragen die sterk correleren dicht bij elkaar te plotten en met een dikkere lijn te verbinden (een zogenaamde netwerk plot), kunnen we de patronen visualiseren. De vraag over het verwachte verloop is hierbij niet meegenomen omdat deze vraag geen duidelijke hiërarchische volgorde van antwoordopties heeft.

**Figuur 5: Netwerk plot van correlaties tussen de case-mix vragen**



De sterkste correlaties (> 0.4) zien we tussen die vragen die gaan over ADL / IADL (maaltijd bereiden, wassen, kleden, mobiliteit, voeden, toilet). De cognitieve vraag correleert het sterkst met de vraag over medicatie, en enigszins met de mantelzorger vraag, maaltijd bereiden en voeden. Wat opvalt is dat de continence vraag minder correleert. Dit kan ook komen door de codering van de vraag. De mantelzorger vraag correleert het sterkst met de maaltijd vraag (IADL) en kleden en wassen (ADL), en enigszins met de cognitieve vraag en de overige (I)ADL vragen. Doordat sommige vragen sterk correleren, zouden deze vragen elkaar mogelijk kunnen vervangen in een cliëntprofiel-indeling.

#### **Extra case-mix kenmerk 'wond / decubitus' door combinatie van NANDA en Omaha**

De case-mix vragenlijst bevat geen vraag over het hebben van een wond, omdat dit kenmerk niet expliciet opviel bij het vooronderzoek dat de basis vormde voor de case-mix vragenlijst. Echter, we zien dat voor een (klein) deel van de cliënten op alle vragen van de case-mix vragenlijst 'zelfstandig / geen hulpvraag' is gescoord. Uit analyse van de NANDA- en Omaha-kenmerken van deze cliënten blijkt dat hun hulpvraag voor een groot deel om wondzorg gaat. Ook uit de eerdere enquête [5] onder wijkverpleegkundigen over welke cliëntkenmerken voorspellend zijn voor de inzet van zorg bleek dat 'complexe of gespecialiseerde zorg', waar wondzorg onder kan vallen, hoog scoorde als voorspeller van zorgvraag.

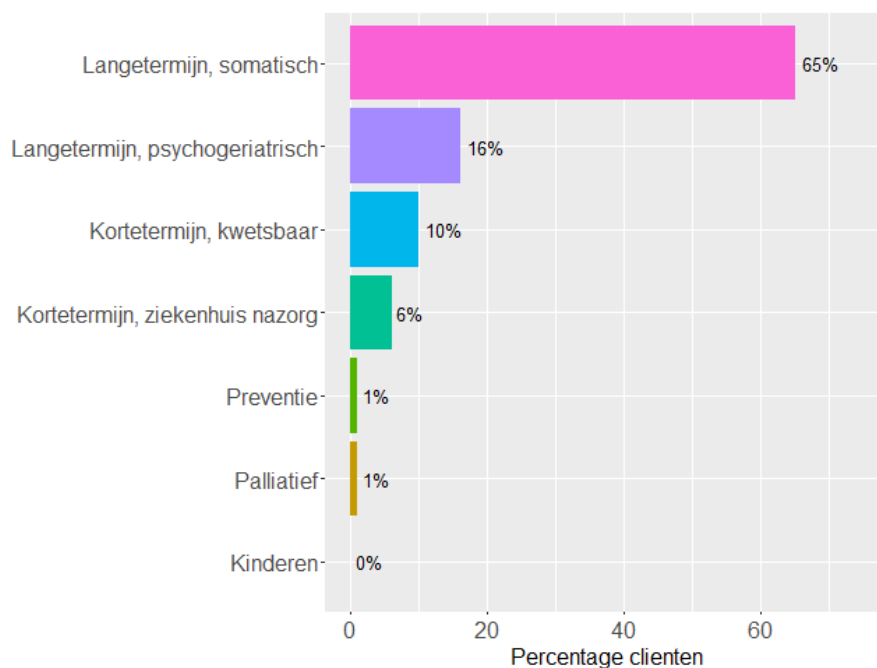
Om deze zorgvraag zichtbaar te maken in de data hebben we gezocht naar een manier om een 'wond' kenmerk te creëren dat vergelijkbare cliënt groepen in Omaha en in NANDA selecteert. Dit bleek lastig; zo is het Omaha aandachtsgebied 'Huid' niet specifiek genoeg aangezien ca. 40% van de zorgplannen dit aandachtsgebied bevat. Uiteindelijk hebben we gebruik gemaakt van de 'Nationale Kernset Patiëntproblemen', in het bijzonder 'wond van huid' [12, 13].

Uit de SNOMED-CT mappings volgt dat een kenmerk 'wond en/of decubitus' het laagste niveau was dat in beide registraties beschikbaar was. Voor dit kenmerk moet in NANDA tenminste één van de diagnoses huiddefect (ND46) of weefseldefect (ND44) aanwezig zijn, en moet in Omaha het signaal 'Wond / decubitus' gescoord zijn. Bij elk van de vier zorgaanbieders scoorde ca 20% (18 – 23%) van de cliënten op dit kenmerk.

### ZN-doelgroepen verdeling

De ZN-doelgroepenregistratie maakte ook onderdeel uit van de aangeleverde data. Zoals blijkt uit figuur 6, vallen de cliënten in de dataset voor ongeveer 65% in de doelgroep **Langetermijn, somatisch**. De ZN-doelgroep **Kindzorg** werd nauwelijks gescoord en is daarom buiten dit onderzoek gelaten.

**Figuur 6: Aandeel cliënten per doelgroep per maand, gemiddeld over pilotperiode**




### Verdeling van de uren over functieniveaus

Gemiddeld werd er per maand iets meer dan 12 uur zorg geleverd per cliënt. We hebben deze uren ingedeeld in de vier functieniveaus. In figuur 7 is de procentuele verdeling over de gehanteerde functieniveaus weergegeven<sup>3</sup>. Ongeveer 55% procent van de uren zorg per maand werd geleverd door verzorgenden (vertaald als Certified Nursing assistant (EQF 3)).


<sup>3</sup> Bij de 78 aanbieders uit het "Onderzoek tariefherijking verpleging en verzorging" van PwC werd ook het grootste deel van de zorguren geleverd door verzorgenden (ca. 51%), 20,5% door MBO verpleegkundigen, 18,1% door HBO verpleegkundigen (niveau 5/6), en 7,8% door helpenden.

**Figuur 7: Verdeling uren zorg per maand over functieniveaus**



We hebben gewichten aan elk functieniveau toegekend om recht te doen aan de kostenverschillen tussen de functieniveaus. In figuur 8 zijn de functieniveaus met hun weegfactoren te zien. Daarbij wordt per functieniveau getoond hoeveel **gewogen** formele uren zorg per cliënt er in een gemiddelde kalendermaand zijn geleverd. Het functieniveau 'certified nursing assistant' (gewicht 1,00) leverde gemiddeld de meeste gewogen uren, namelijk 6,8. In verhouding is het verschil met de functieniveaus voor 'registered nurse' iets kleiner geworden, omdat deze functies een zwaardere wegingsfactor hebben.

**Figuur 8: Gewogen uren zorg in gemiddelde kalendermaand, per functieniveau**

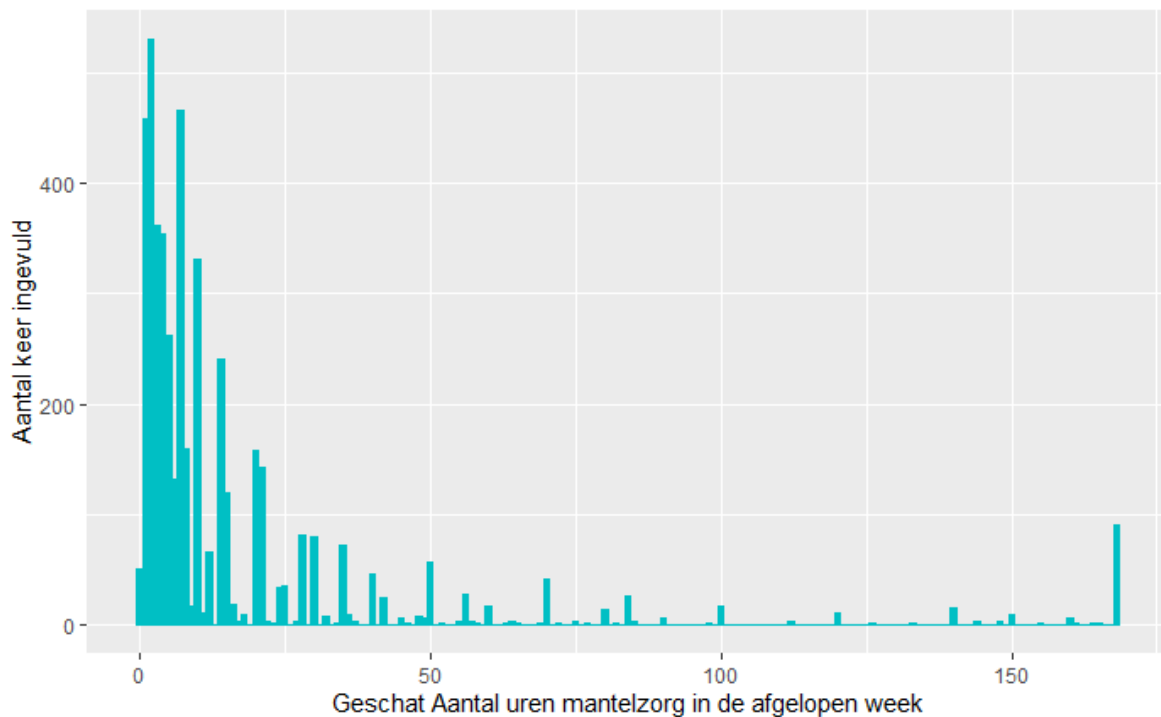


### Verdeling uren informele zorg

De verdeling van de geschatte uren informele zorg in de week voorafgaand aan het invullen van de case-mix vragenlijst is hieronder weergegeven in figuur 9. Het merendeel van de waardes ligt tussen de 0 en 10 uur informele zorg per week, maar de verdeling heeft een lange staart richting hogere aantallen uren. Voor een deel van de cliënten is aangegeven dat er sprake was van 24/7 mantelzorg (168 uur informele zorg op weekbasis).

Dat het een schatting is van de hoeveelheid mantelzorg in een week, blijkt uit het veelvuldig voorkomen van veelvoudigen van 10 uur (10, 20, 30 etc.) en van veelvoudigen van 7 (7, 14, 21 etc.), er is dan een aantal uur per dag geschat en maal 7 gedaan).

**Figuur 9: Verdeling uren informele zorg bij cliënten met een case-mix vragenlijst**



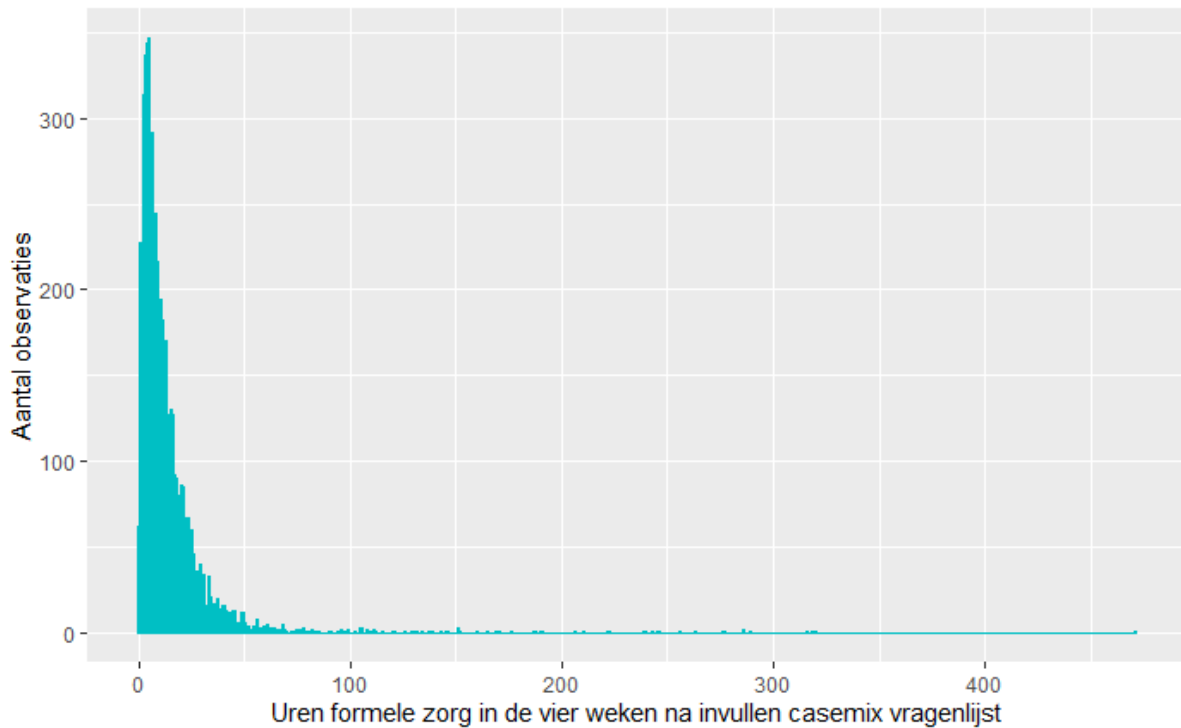
## 2.2 Resultaten modellen formele uren

Deze paragraaf bevat de resultaten van de voorspelmodellen waarbij we de formele uren voorspellen aan de hand van de diverse groepen met cliëntkenmerken. Het voorspellen van de formele uren is het voornaamste doel omdat het doel van dit onderzoek is te komen tot cliëntprofielen voor formele zorginzet. Voor de formele uren is gekeken naar de zorginzet in de vier weken na het invullen van de case-mix vragenlijst.

Figuur 10 bevat de verdeling van de te voorspellen variabele. Ook hier zien we een scheve verdeling met een piek. Veruit de meeste cliënten ontvangen in die vier weken **enkele uren tot zo'n 30 uur formele zorg**, hoewel er ook een klein aantal cliënten veel meer zorg ontvangt, tot wel zo'n 500 uur in de lange staart van de figuur.



**Figuur 10: Verdeling van de uren formele zorg in de vier weken na het invullen van de case-mix vragenlijst**



Omdat we data van vier zorgaanbieders samenvoegen, moeten we rekening houden met mogelijk structurele verschillen in ureninzet tussen deze zorgaanbieders (het is een zogenaamde multi-level dataset, waarbij cliënten zijn geclusterd binnen de zorgaanbieders). Het blijkt dat corrigeren voor verschillen in ureninzet tussen de vier zorgaanbieders in dit geval weinig uit maakt voor de voorspelkracht (zie bijlage B 'Extra analyses'). Hier rapporteren we daarom alleen modellen gebaseerd op de werkelijke geleverde uren van alle vier de zorgaanbieders.

In tabel 3 is voor de verschillende groepen van cliëntkenmerken weergegeven in welke combinaties deze cliëntkenmerken zijn onderzocht op voorspelkracht. De linker kolom geeft het label weer wat we aan deze combinatie van kenmerken hebben gegeven voor het presenteren van de resultaten. **Ter verduidelijking: label 'Case-mix +' refereert naar een model waarbij de cliëntkenmerken uit de case-mix vragenlijst, het kenmerk wond/decubitus, de mantelzorgvraag en leeftijd/geslacht zijn meegenomen als voorspellers.**

**Tabel 3: Combinaties van voorspellers modellen formele uren**


Voorspellers	Zn-doelgroepen	Case-mix vragenlijst*	Wond/decubitus	Mantelzorgvraag	Leeftijd/geslacht	Geschatte informele uren
Label						
Zn-doelgroepen	X					
Case-mix		X	X			
Case-mix +		X	X	X	X	
Case-mix + & ZN-doelgroepen	X	X	X	X	X	
Case-mix & informele uren		X	X			X

\*) Met case-mix wordt bedoeld alle vragen uit de case-mix vragenlijst, met uitzondering van de maaltijdvraag en de mantelzorgvraag.

## 2.2.1 Voorspelkracht formele uren ligt rond de 20%

In figuur 11 is de R-kwadraat voorspelkracht weergegeven van deze modellen, waarbij we de formele uren voorspellen met behulp van de voorspellers uit tabel 3. De beslisboom analyses zijn tien keer herhaald met telkens een andere verdeling van de data over de cross-validatie folds. De min-max spreiding in deze tien herhalingen is weergegeven met de liggende zwarte 'error bars'. De resultaten op basis van het random forest algoritme is als benchmark weergegeven met een verticale lijn: dit is wat machine learning maximaal uit de data kan halen. Het geel geaccentueerde model in de figuur is het model waar de rest van deze paragraaf op doorgaat.

**Figuur 11: CART en random forest resultaten (formele uren)**




We zien in de figuur dat de ZN-doelgroepen circa 10% voorspelkracht hebben voor de formele uren zorg. Ook zien we dat de case-mix vragenlijst (inclusief het wond/decubitus kenmerk) een voorspelkracht heeft van circa 21%, en dat het combineren van beide sets niet leidt tot een hogere voorspelkracht. Ook het toevoegen van de mantelzorgvraag en leeftijd/geslacht als voorspellers heeft geen toegevoegde waarde voor de beslisboom. Zoals verwacht haalt de beslisboom niet het maximale aan voorspelkracht uit de data van de case-mix vragenlijst. Het verschil is circa 5%-punt R-kwadraat extra met het random forest model.

### *Effect van toevoegen informele uren als voorspeller*

Een belangrijke reden voor het meenemen van de informele zorguren als voorspeller is de verwachting dat dit van invloed is op het aantal formele zorguren, zoals toegelicht in de onderzoeks aanpak. Figuur 12 laat zien wat het toevoegen van de geschatte informele uren als voorspeller doet in het model waarin we de formele uren willen voorspellen. We zien dat de random forest resultaten enigszins verbeteren (van 25% R-kwadraat naar 27% R-kwadraat). Voor de beslisboom geldt dit niet.

**Figuur 12: CART en random forest resultaten bij toevoegen informele uren als voorspeller (formele uren)**

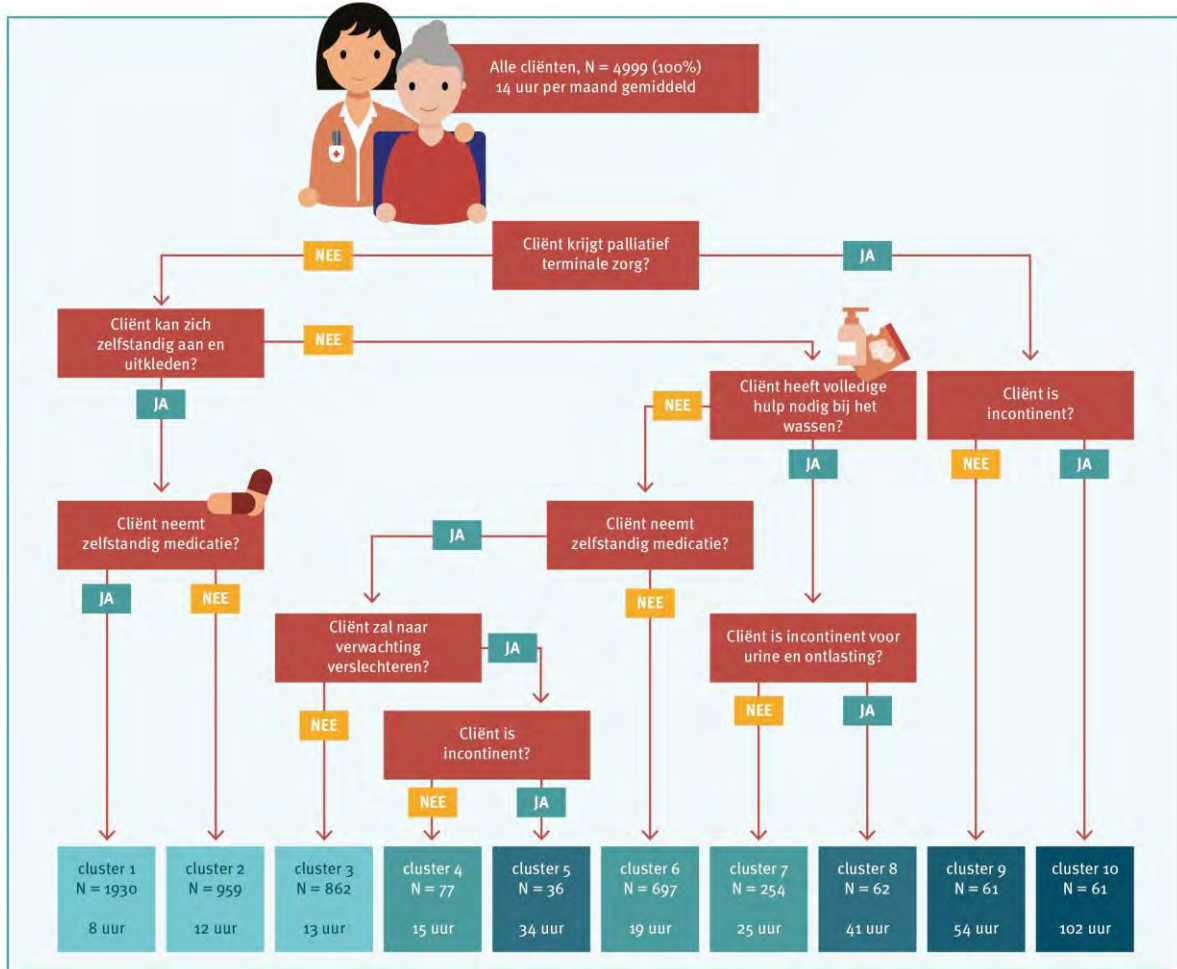


Gezien de verwachting is het verrassend te noemen dat het aantal uren informele zorg nauwelijks voorspellend is voor het aantal uren formele zorg *in onze dataset*. We kunnen hier ook uit afleiden dat de aan- of afwezigheid van een mantelzorger op basis van onze data ook niet voorspellend is. **Als dit wel zo was geweest, hadden de algoritmes namelijk een splitsing kunnen maken op 'meer dan 0 uren informele zorg'.** In de discussie gaan we in op mogelijke verklaringen voor deze uitkomsten.

### 2.2.2 Beslisboom formele uren leidt tot 10 cliëntprofielen

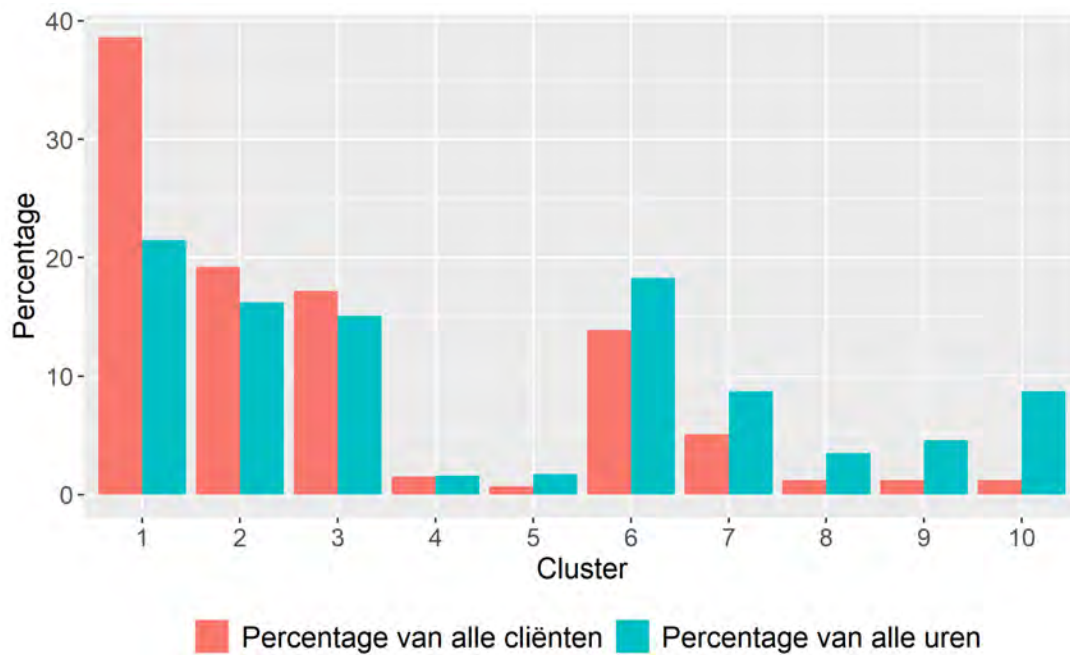
Uiteindelijk heeft het case-mix model als doel om cliënten op basis van hun formele zorgvraag in te delen in cliëntprofielen. Figuur 13 geeft de beslisboom weer voor het voorspellen van de formele zorg in de vier weken na aanmaken van de case-mix vragenlijst. Dit model verklaart 21% (uitgedrukt in R-kwadraat) van de variatie. Dit model leidt tot tien cliëntprofielen. Het kenmerk of iemand palliatief terminale zorg (PTZ) ontvangt, komt hier als eerste splitsing naar voren. In de beslisboom is per cliëntprofiel (cluster) het aantal cliënten vermeld en het gemiddeld aantal formele uren zorg (gewogen naar functieniveau).

**Figuur 13: Beslisboom formele uren**



Figuur 14 geeft voor elke cliëntprofiel weer welk percentage van alle cliënten van de vier zorgaanbieders in deze groep valt (oranje balk). Daarnaast (blauwe balk) staat per cliëntprofiel het percentage van alle gewogen zorguren weergegeven. Hoewel de twee zwaarste cliëntprofielen (daar waar sprake is van PTZ) een klein deel van het aantal cliënten omvat (samen ca. 2,5%), zijn deze cliënten samen verantwoordelijk voor ruim 13% van alle geleverde zorguren. Het meest voorkomende cluster is cluster 1 met bijna 40% van de cliënten en ongeveer 20% van de geleverde zorguren.


**Figuur 14: Percentage cliënten & percentage uren (formeel) per cluster**



#### *Spreiding binnen de clusters*

De cliëntprofielen leiden tot een vermindering in de spreiding van zorginzet tussen de cliënten. Alleen als de verklaarde variantie 100% zou zijn, zou dit betekenen dat er geheel geen spreiding meer aanwezig zou zijn binnen elk cliëntprofiel. De resterende spreiding in de cliëntprofielen die volgen uit de beslisboom is weergegeven in figuur 15. Het rode cijfer geeft het gemiddelde aantal uren weer in elke groep. Het figuur laat zien dat de spreiding toeneemt als de cliëntprofiel zwaarder wordt (gemiddeld meer zorguren ontvangt).

**Figuur 15: Spreiding en gemiddelde van de beslisboom groepen voor formele uren zorg**

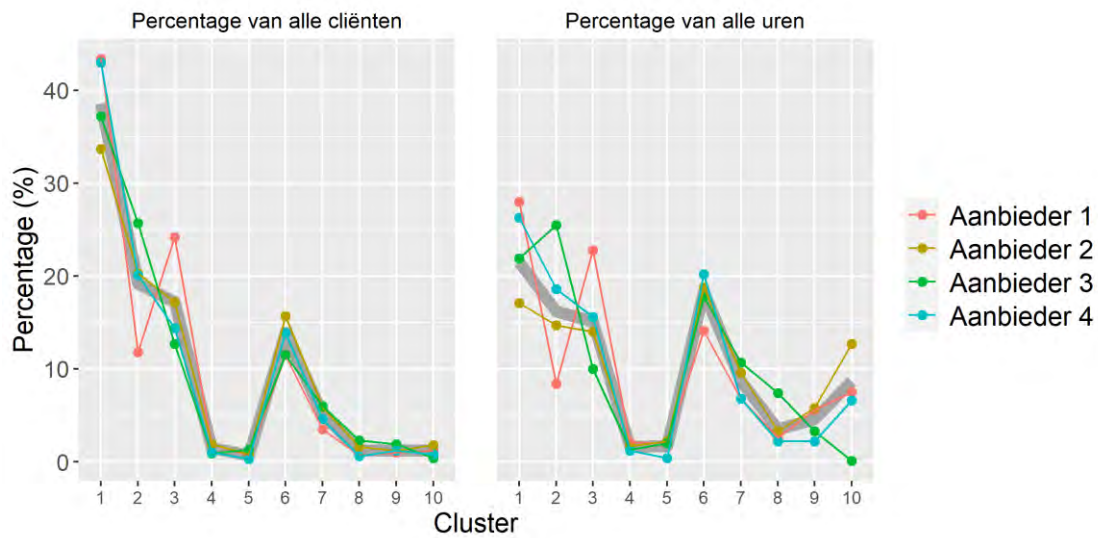


### 2.2.3 De modellen toegepast op de vier zorgaanbieders

We kunnen de beslisboom, gemaakt op de data van de vier zorgaanbieders samen, toepassen op de afzonderlijke zorgaanbieders. Hierdoor krijgen we een indicatie van hoe robuust de cliëntprofielen zijn bij mogelijke verschillen tussen zorgaanbieders, cliëntenpopulaties en/of regio's. Dit geeft een eerste indicatie van de toepasbaarheid van de modellen bij soortgelijke zorgaanbieders buiten de pilot.

We zien in figuur 16 dat de verdeling van cliënten en uren zorg over de clusters (cliëntprofielen) per zorgaanbieder in grote lijnen lijkt op de verdeling wanneer we het model op de volledige dataset (alle vier de zorgaanbieders) toepassen. De grijze lijn toont de verdeling voor alle vier de zorgaanbieders samen en de gekleurde lijnen de verdeling voor de afzonderlijke zorgaanbieders.

**Figuur 16: Percentage cliënten & percentage uren (formeel) per zorgaanbieder, per cluster**



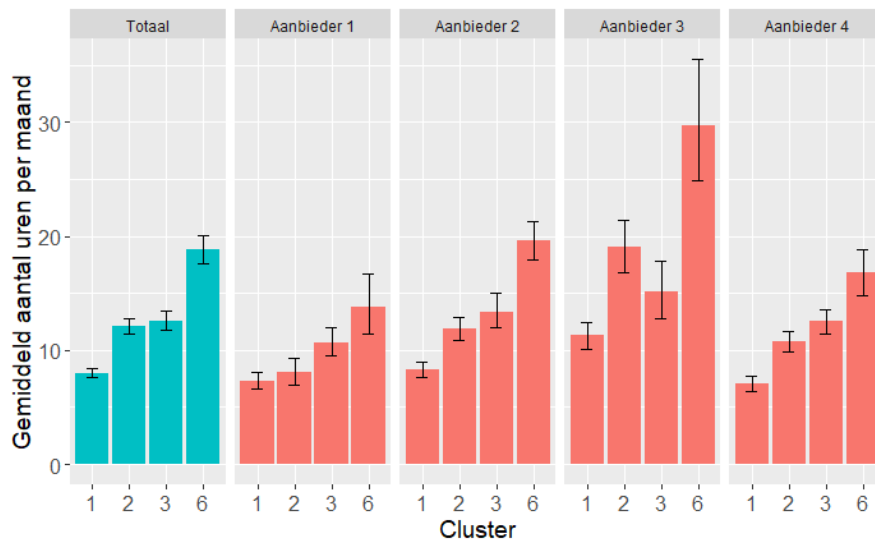
**Patronen gemiddelde uren per cliënt tussen zorgaanbieders vergelijkbaar**

Als we inzoomen op de clusters die bij elke zorgaanbieder minimaal 35 cliënten bevatten, houden we vier clusters over. Voor deze clusters zien we in figuur 17 bij elk van de vier zorgaanbieders hetzelfde relatieve patroon, waarbij:

- in cluster 1 gemiddeld de minste uren geleverd worden (bij alle aanbieders rond de 8 uur),
- er in clusters 2 en 3 er meer uren geleverd worden,
- dat de uurgemiddeldes van deze twee clusters dicht bij elkaar liggen, en
- dat in cluster 6 bij alle vier de meeste uren geleverd worden (variërend van 14 tot 30 uur).

De errorbars geven een indruk van de onzekerheid bij het schatten van het gemiddelde (bootstrap interval tussen 2.5% en 97.5%, 1000 repeats).

**Figuur 17: Gemiddelde formele uren per cliënt per cluster**



## 2.2.4 Voorspelkracht varianten met exclusie


In een praktische uitwerking van het case-mix model kan er met boven- en ondergrenzen gewerkt worden, waar andere regels voor bekostiging gelden. Om aan te geven wat dit zou betekenen voor de voorspelkracht laten we een aantal voorbeelden van dergelijke selecties zien. Tabel 4 geeft weer om welke voorbeelden het gaat: 1) een bovengrens van meer dan 85 uur wijkverpleegkundige zorg per maand, en/of 2) een ondergrens van tenminste vijf afzonderlijke contactmomenten en/of 3) een meer inhoudelijk exclusiecriteria of het gaat om een cliënt met palliatief terminale zorg. De rechter kolom laat zien wat het effect is van excluderen op het aantal observaties.

**Tabel 4: Gekozen voorbeelden van in- en exclusie criteria**

Exclusie criteria	Excl. < 5 contactmomenten	Excl. PTZ	Excl. > 85 uur per maand	N observaties
<b>label</b>				
Alle cliënten				<b>4.999</b>
Alle cliënten				<b>4.999</b>
Excl. < 5 contactmomenten	<b>X</b>			<b>4.423</b>
Excl. PTZ		<b>X</b>		<b>4.877</b>
Excl. PTZ en/of > 85 uur p/maand		<b>X</b>	<b>X</b>	<b>4.850</b>
Excl. PTZ en/of > 85 uur p/maand en/of < 5 contactmomenten	<b>X</b>	<b>X</b>	<b>X</b>	<b>4.287</b>

Figuur 18 toont wat de selecties met de voorspelkracht doen. Om het effect van de selecties op de data te kunnen vergelijken, is de set voorspellers gelijk gehouden (case-mix vragenlijst + wond/decubitus kenmerk). We zien dat het excluderen van cliënten met meer uren dan de bovengrens van 85 uur zorg per maand en/of palliatieve cliënten, leidt tot modellen met een lagere voorspelkracht. Het excluderen van cliënten met minder dan vijf contactmomenten leidt tot een model met een hogere voorspelkracht.

**Figuur 18: CART en random forest resultaten op selecties van de data (formele uren, case-mix voorspellers)**



## 2.3 Regressie als alternatieve modelleerstrategie

Het heeft de voorkeur om tot een beperkte set van cliëntprofielen te komen. Het CART algoritme dat leidt tot een beslisboom is een techniek die hier goed bij past en daarom gekozen is. Een alternatieve modelleerstrategie is (multivariate) lineaire regressie. Deze techniek gaat ervan uit dat de te voorspellen variabele een (gewogen) optelsom is van de voorspellende kenmerken.

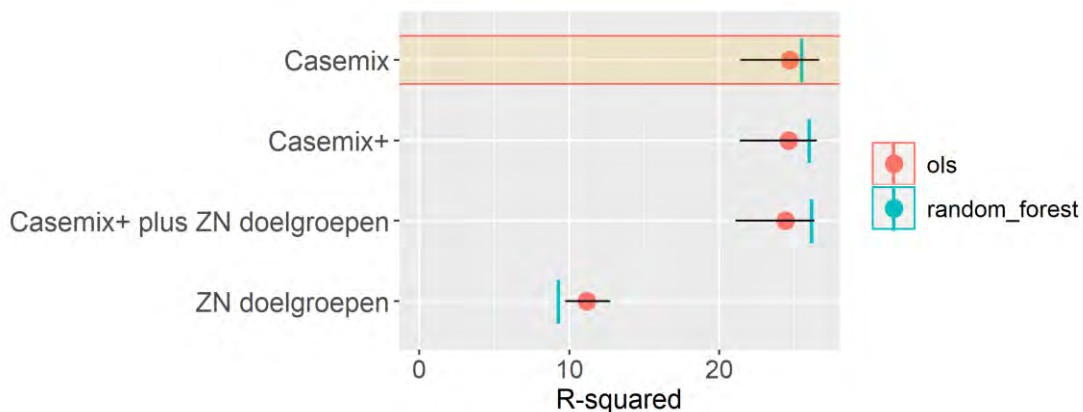
Als de te verwachten ureninzet bij benadering (grosfweg) een optelsom is van afzonderlijke hulpvragen dan is regressie mogelijk beter in staat om de benodigde uren te voorspellen dan CART-beslisbomen. Er wordt namelijk gelijktijdig het effect van elk extra probleem geschat. Dit in tegenstelling tot CART: doordat de beslisboom telkens groepjes apart zet, wordt de beschikbare data om nog extra verbanden te vinden telkens verdund.

Ter illustratie: na een aantal splitsingen op bijv. kleden en wassen zijn de cliënten met bijv. decubitus/wond verspreid geraakt over meerdere clusters, en het kan dan zo zijn dat er in elk cluster nog onvoldoende cliënten over zijn om een goede voorspelling voor dit kenmerk te detecteren, terwijl deze cliënten als groep samen genomen wel iets meer uren zorg laten zien.

### Resultaat multivariate regressie modellen

Figuur 19 geeft het resultaat weer als we multivariate regressie toepassen op de verschillende combinaties van voorspellers. Hiermee vinden we een R-kwadraat van 25% voor de formele uren, wat hoger is dan de R-kwadraat van 21% wanneer we beslisbomen gebruiken.

**Figuur 19: Regressie ('ordinary least squares') en random forest resultaten (formele uren)**




Wat opvalt is dat we met regressie analyse heel dicht op het resultaat van het random forest algoritme komen, wat we als een benchmark voor het maximaal haalbare voorspelresultaat beschouwen. Dit suggereert dat interactie-effecten een beperkte rol spelen bij de voorspelkracht van de algoritmes die hiervoor gevoelig zijn, namelijk CART en random forest. Dit kan verklaard worden door het feit dat er veel bronnen van variatie in formele uren zijn die we niet modelleren, en dat voor het betrouwbaar detecteren van interactie-effecten (veel) meer data nodig is dan nu verzameld is.

In figuur 20 geven we de gevonden regressie coëfficiënten weer voor het meest compacte model: de case-mix vragenlijst zonder mantelzorgvraag, zonder voedenvraag, en met het wond/decubitus kenmerk. Of een cliënt palliatief terminale zorg ontvangt (VR\_verloop.5) heeft veruit de grootste bijdrage aan het voorspelde aantal uren zorg met een coëfficiënt van ongeveer 50. De overige kenmerken dragen tussen de 0 en 12 uur bij.



**Figuur 20: Regressie coëfficiënten**



Om met de regressie coëfficiënten ( $w_1, w_2, w_3 \dots$ ) een voorspelling te doen voor een specifieke cliënt dient de regressie formule te worden ingevuld:

*Verwacht aantal uren formele zorg  $\sim$  constante +  $w_1 * kenmerk 1 + w_2 * kenmerk 2 + \dots$  etc.*

Bijvoorbeeld: Voor een cliënt die zelfstandig is op alle cliëntkenmerken, en geen PTZ ontvangt (antwoordoptie 5 op de verloop vraag) wordt 5 uur per maand voorspeld (dit is de constante term 'intercept' in het regressie model). Wanneer een cliënt PTZ ontvangt komt hier circa 50 uur bij; als de cliënt incontinent is voor urine en ontlasting komt er nog 11 uur bij etc.

#### ***Van multivariate regressie naar case-mix model***

Stel dat we van deze kenmerken cliëntprofielen (een case-mix model) willen maken, dan moet er voor elke unieke combinatie van cliëntkenmerken een apart cliëntprofiel komen. Dit kan in een zeer groot aantal cliëntprofielen resulteren. Voor bovenstaand model komen we op  $2$  (PTZ)  $\times$   $4$  (Continentie)  $\times$   $3$  (toilet)  $\times$   $3$  (kleden)  $\times$   $3$  (wassen)  $\times$   $2$  (medicatie)  $\times$   $2$  (Wond/decubitus) = 864 cliëntprofielen uit. Dit is een nadeel van regressie analyse ten opzichte van beslisbomen. Er zullen ook combinaties van cliëntkenmerken tussen zitten die vrijwel nooit voorkomen.

## **2.4 Resultaten modellen formele + informele uren**

Deze paragraaf bevat de resultaten van de voorspelmodellen waarbij we de gewogen optelsom van formele en informele uren voorspellen aan de hand van de diverse combinaties van cliëntkenmerken. Voor de formele uren is de zorginzet in de vier weken na het invullen van de case-mix vragenlijst gehanteerd. Voor de informele uren is aangenomen dat de schatting van de wijkverpleegkundige voor de week voorafgaand aan het invullen van de case-mix vragenlijst gelijk blijft in de daaropvolgende vier weken.

In tabel 5 zijn de combinaties van voorspellers weergegeven die voor de uitkomstmaat formele + informele uren zorg doorgerekend zijn. De linker kolom geeft aan welk label gehanteerd wordt bij het presenteren van de resultaten.

**Tabel 5: Combinaties van voorspellers modellen formele + informele uren**


<b>Voorspellers</b> <b>Label</b>	<b>ZN-doelgroepen</b>	<b>Case-mix vragenlijst*</b>	<b>Wond/ Decubitus</b>	<b>Mantelzorger vraag</b>	<b>Leeftijd/ geslacht</b>
ZN-doelgroepen	X				
Case-mix		X	X		
Case-mix+		X	X	X	X
Case-mix+ & ZN-doelgroepen	X	X	X	X	X

\*) Met case-mix wordt bedoeld alle vragen uit de case-mix vragenlijst, met uitzondering van de maaltijd vraag en de mantelzorger vraag.

#### *Te voorspellen uren voor ca. 35% formele uren*

Zoals in de aanpak uitgelegd zijn alle uren gewogen. Hierbij zijn de informele uren met weegfactor 0,5 vermenigvuldigd. In figuur 21 is te zien dat het aandeel gewogen formele uren 35% is van het totaal aan gewogen uren in het onderzoeksbestand (N = 4999).

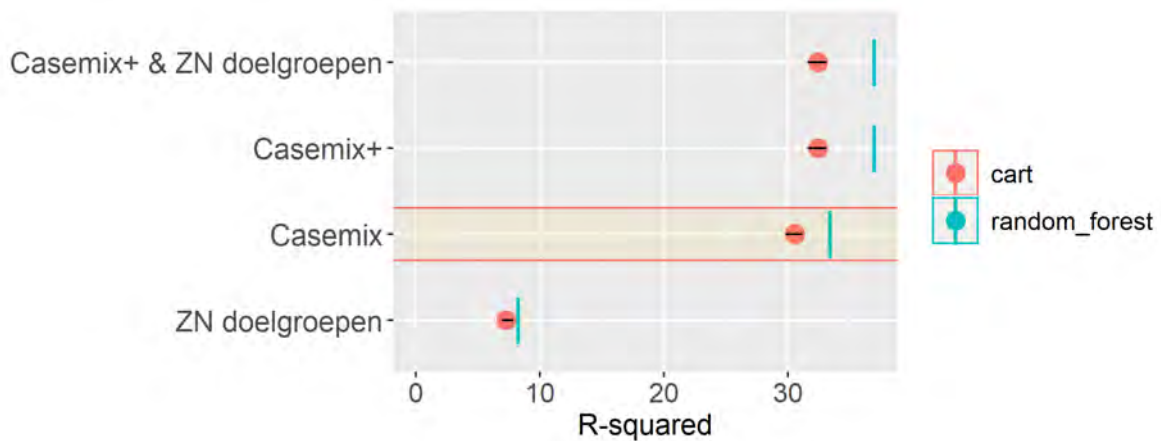
**Figuur 21: Formele uren zijn 35% van de gewogen optelsom van uren zorg**



### Resultaten voorspelkracht

In figuur 22 is de R-kwadraat voorspelkracht weergegeven van de modellen waarbij we de optelsom van formele en informele uren voorspellen met behulp van de voorspellers uit tabel 5. De beslisboom analyses zijn tien keer herhaald met telkens andere verdeling van de data over de cross-validatie folds. De min-max spreiding in deze tien herhalingen is weergegeven met de liggende zwarte 'error bars'. De resultaten op basis van het random forest algoritme is als benchmark weergegeven met een verticale lijn: dit is wat machine learning maximaal uit de data kan halen.

**Figuur 22: CART en random forest resultaten (formele en informele uren)**



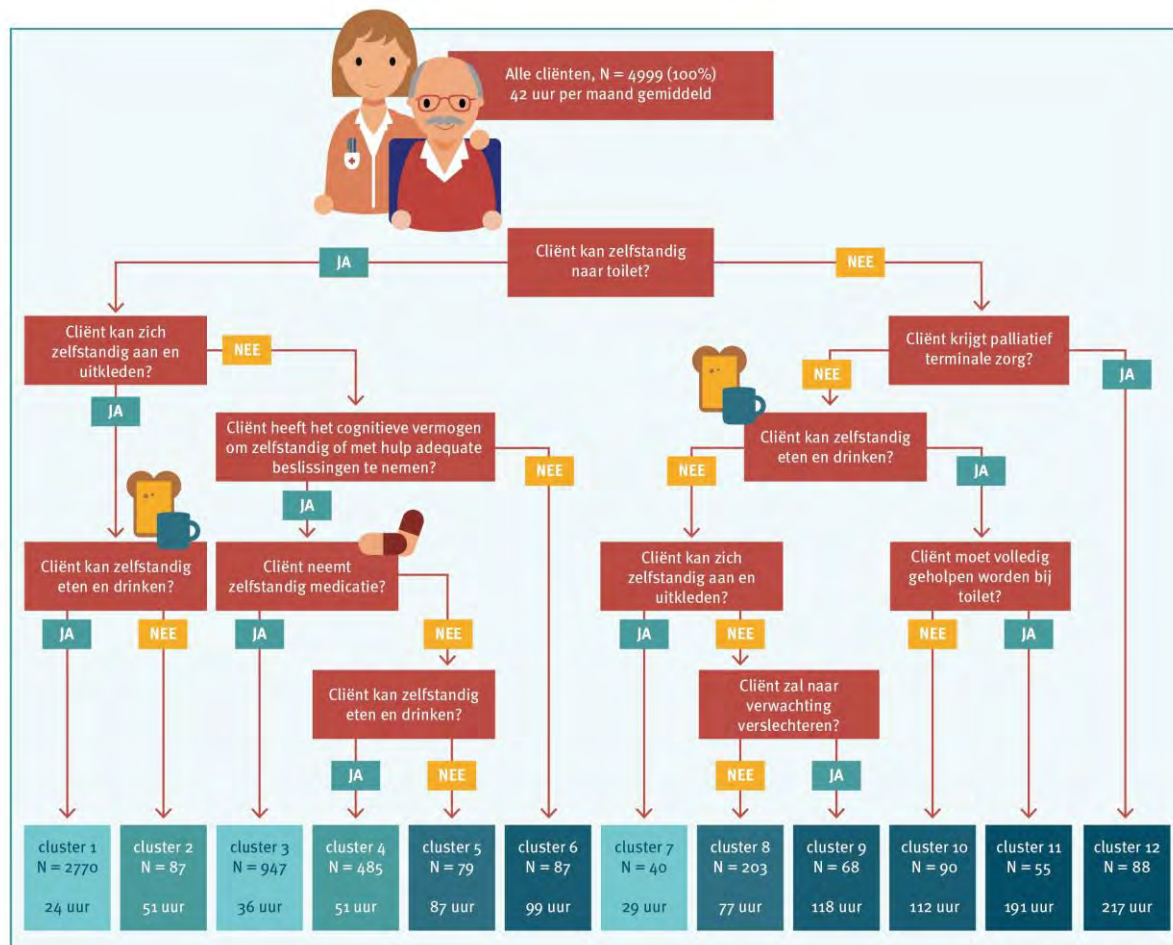
We zien in figuur 22 dat de ZN-doelgroepen een voorspelkracht hebben van ca. 7%. De case-mix vragenlijst (inclusief wond/decubitus) heeft een voorspelkracht van 31%.

Zoals verwacht haalt de losse beslisboom niet het maximale aan voorspelkracht uit de data, het verschil is ca. 3% punt R-kwadraat. Het combineren van de case-mix vragenlijst en de ZN-doelgroepen leidt niet tot een hogere voorspelkracht. Het toevoegen van de mantelzorgvraag en leeftijd/geslacht verhoogt de R-kwadraat iets, naar 32%. Het blijkt dat de extra voorspelkracht uit de mantelzorgvraag komt. Omdat we informatie over informele zorg niet willen gebruiken voor cliëntprofielen gericht op bekostiging, richten we ons in het vervolg van deze paragraaf op de beslisboom zonder mantelzorgvraag (geel gearceerd in figuur 22). Het verschil in voorspelkracht is niet groot (31% vs. 32%).

### Beslisboom formele + informele uren leidt tot 12 cliëntprofielen

In figuur 23 is de beslisboom weergegeven die hoort bij het model dat 31% (uitgedrukt in R-kwadraat) van de variatie in totale uren zorg verklaart. Per cliëntprofiel is in de beslisboom het aantal cliënten vermeld (N) dat afleidt naar deze groep, en het gemiddeld aantal uur formele en informele zorg (gewogen naar functieniveau). We zien dat het model bestaat uit twaalf cliëntprofielen. Er wordt informatie afkomstig van zes vragen uit de case-mix vragenlijst gebruikt. Net als in de beslisboom voor formele zorginzet, is het kenmerk PTZ een belangrijk kenmerk om zware cliënten mee in te delen. Iets meer dan de helft van de cliënten valt in het lichtste cliëntprofiel met gemiddeld 24 uur zorg per maand. Dit zijn cliënten die volledig zelfstandig naar het toilet kunnen, zich zelfstandig aan en uit kleden, en zelfstandig eten en drinken.

**Figuur 23: Beslisboom formele en informele uren**




### 2.4.1 Regressie resultaat voor formele + informele uren

Ook voor de combinatie formele en informele uren hebben we multivariate regressie toegepast, en vergeleken met random forest.

Net als bij de formele uren blijkt dat regressie vergelijkbare voorspelkracht (R-kwadraat van 37% voor de case-mix vragenlijst inclusief mantelzorgvraag en leeftijd/geslacht) kan behalen als de random forest. Dit wordt getoond in figuur 24.

Omdat de regressie modellen geen interactie termen bevatten, volgt dat interacties hier geen rol lijken te spelen bij het voorspellen van het totaal aan zorguren dat een cliënt ontvangt. Naast het kenmerk palliatieve zorg en de mantelzorgvraag zijn de kenmerken voeden, toilet en kleden de voorspellers die de meeste extra uren voorspellen in het regressie model.

Figuur 24: Regressie (ols) en random forest resultaten (formele en informele uren)



# 3. Discussie en conclusie

Uit dit onderzoek blijkt dat de case-mix vragenlijst een maximale voorspelkracht voor de zorginzet van wijkverpleging heeft van 25% op basis van het random forest algoritme. Dit is aanzienlijk meer dan de huidige cliëntprofielen in wijkverpleging, de ZN-doelgroepen. Deze kenmerken hebben een R-kwadraat van circa 10%. De voorspelkracht zit bij de ZN-doelgroepen vooral in het kunnen onderscheiden van palliatieve cliënten. De overige doelgroepen verschillen wel qua uurgemiddelden [8], maar zijn vanwege de enorme spreiding in uren slechts beperkt informatief<sup>4</sup>.

De gevonden beslisboom voor formele uren zorg leidt af naar 10 cliëntprofielen en heeft een voorspelkracht van 21%. We zien dat net als in het Nieuw-Zeelandse model [14], het model vooral arbeidsintensieve elementen als hulp met wassen, hulp met kleden, etc. selecteert. Kenmerken uit de ZN-doelgroepen worden niet geselecteerd door het CART-algoritme. Wanneer we Omaha- of NANDA-kenmerken uit de anamnese of het zorgplan toevoegen, zien we slechts een beperkte toename in de voorspelkracht. De gevonden cliëntprofielen zijn enkel gebaseerd op de case-mix vragenlijst, wat het mogelijk maakt om los van systemen als Omaha en NANDA op uniforme wijze een cliënttypering te hanteren. De wijkverpleegkundigen die betrokken waren bij het onderzoek geven aan dat zij de inzichten uit de case-mix vragenlijst waardevol vinden.

Er was een klein deel van de cliënten dat puur op basis van de case-mix vragenlijst geen zorgvraag leek te hebben. Uit analyse van de NANDA- en Omaha-kenmerken uit de zorgplannen bleek dat het bij een groot deel van deze cliënten om wondzorg ging. Alleen de aanwezigheid van een wond **of** decubitus kon als kenmerk in beide classificatiesystemen worden geïsoleerd. Alhoewel het wondzorg/decubitus kenmerk niet wordt geselecteerd in de beslisboom, voegt het wel enige voorspelkracht toe bij de regressie analyse voor de formele uren.

---

<sup>4</sup> Voorbeeld: Door te weten dat iemand doelgroep Langetermijn, psychogeriatrisch heeft en een ander doelgroep Korte termijn, ziekenhuis nazorg zal je bij de eerste cliënt een voorspelling van bijv. 12 uur p/m doen, en bij de tweede 10 uur p/m, maar de werkelijke uren kunnen nog steeds tussen de 0 en 300 liggen. Dit werkt vervolgens slechts beperkt door in de R-kwadraat.

### ***Wat is nu de belangrijkste uitkomst van het onderzoek?***

Dit onderzoek laat zien dat je met een korte vragenlijst cliëntprofielen voor wijkverpleging op kunt stellen met vergelijkbare voorspelkracht ten opzichte van reeds bestaande case-mix modellen voor thuiszorg in andere landen. Dit heeft praktisch potentieel omdat het om een beperkte registratie gaat en onafhankelijk van de verpleegkundige classificatiesystemen gebruikt kan worden.

### ***Informele zorg en wijkverpleegkundige zorg***

In dit onderzoek is zowel de aanwezigheid van een mantelzorger, als ook het aantal uren informele zorg nauwelijks voorspellend voor het aantal uren formele zorg. Op zichzelf genomen is het niet gek dat de uren informele zorg niet voorspellend zijn voor uren formele zorg: iemand kan een lichte zorgvraag hebben die vrijwel volledig door een mantelzorger wordt ingevuld, of iemand kan een zware zorgvraag hebben die voor een klein deel door een mantelzorger, maar voor een groot deel door formele zorg wordt ingevuld. Echter, de overige case-mix vragen brengen juist die zorgvraag in beeld. Wanneer we twee cliënten vergelijken die op de overige vragen vergelijkbaar scoren, was wel de verwachting dat er een relatie tussen informele en formele zorg zichtbaar wordt. Dat dit niet uit ons onderzoek volgt, kan verschillende oorzaken hebben. De informele uren zijn geschat door de verpleegkundige, en gaan over de week voorafgaand aan de indicatiestelling / herindicatie (dit is bewust gedaan om een zo goed mogelijke inschatting te krijgen), terwijl de formele uren over de vier weken ná indicatiestelling / herindicatie gaan. De gehanteerde definitie voor informele zorg is ook iets breder gesteld dan de scope van wijkverpleegkundige zorg (huishoudelijke taken worden ook genoemd). Daarnaast hangt het van de zorgvraag en de capaciteiten van de mantelzorger af welk deel van de zorgvraag door informele zorg kan worden vervuld (omdat deze fysiek te belastend is, medisch technisch is, of gevoelig ligt, zoals bij wassen **of hulp bij de toiletgang**). **Het is dus aannemelijk dat verscheidene 'meetfouten' maken dat we geen relatie vinden tussen informele en formele zorg.**

### ***Regressie versus beslisbomen***

Zowel voor het voorspellen van formele uren zorg, als voor het voorspellen van de optelsom van formele en informele uren zorg vinden we dat een regressie analyse, waarbij het model uitgaat van een gewogen optelsom van de aanwezigheid van de verschillende cliëntkenmerken, tot een hogere voorspelkracht leidt dan de beslisbomen. Het nadeel van regressie analyse is dat het al snel leidt tot een groot aantal cliëntprofielen: een compact regressie model van 10 cliëntkenmerken leidt tot ruim 800 verschillende combinaties van deze cliëntkenmerken, en dus cliëntprofielen.

### ***Waarom doet regressie het beter dan beslisbomen?***

Uit diverse eerdere onderzoeken weten we dat het aantal problemen dat een cliënt heeft een goede voorspeller is voor het uren zorg [8,15,16]. Dat is ook begrijpelijk: als iemand naast kleden ook een probleem heeft met wassen, is er gemiddeld genomen meer hulp nodig, wat meer tijd kost. Als er vervolgens bijv. ook een cognitieve beperking bij komt waardoor iemand zijn medicatie niet zelfstandig meer inneemt, komt dit er bovenop. Een dergelijke stapeling kan ook door beslisbomen gevonden worden, maar beslisbomen maken minder efficiënt gebruik van de data. Er is nog een statistische reden: om (vaak subtielere) interactie-effecten tussen voorspellers te detecteren is vermoedelijk meer data nodig dan dat er in dit onderzoek is verzameld. Het is bijvoorbeeld **opvallend dat een simpel regressie model zonder interactietermen 'out of sample' even goed presteert als een flexibel machine learning algoritme (zoals random forest) dat interacties automatisch meeneemt [9].**

### ***Generaliseert het model ook naar andere zorgaanbieders?***

We zien dat het gevonden model bij alle vier de zorgaanbieders tot soortgelijke patronen leidt wanneer we kijken naar procentuele verdeling over de cliëntprofielen die uit de beslisboom volgen, en gemiddelde ureninzet binnen de profielen. De zorgaanbieders verschillen in werkgebied (Amsterdam e.o., Maastricht e.o., Parkstad Limburg e.o. en regio Zoetermeer, Midden Holland, Utrecht West), maar zijn allemaal grote zorgaanbieders met een regionale systeemfunctie. Daarentegen is het zorgaanbod in de wijkverpleging divers, variërend van ZZP-ers tot organisaties die landelijk actief zijn, en van zorgaanbieders met een breed aanbod tot zeer specialistische zorgaanbieders voor specifieke doelgroepen. Hoe het model op andersoortige zorgaanbieders zou uitwerken is daarmee lastig te zeggen en zou verder onderzocht moeten worden.

### ***Hoe verhoudt de gevonden voorspelkracht zich met bestaande case-mix modellen in de thuiszorg?***

Uit de systematische review van Van den Bulck et al. (2020) [4] blijkt dat de meeste internationaal bekende case-mix systemen voor thuiszorg / wijkverpleging qua voorspelkracht (R-kwadraat) rond de 20 – 40% liggen. Zo beschouwd sluiten onze bevindingen hier dus goed bij aan.

### ***Mogelijke verklaringen voor de resterende variatie in uren***

Het is niet verrassend dat de R-kwadraat geen 100% is. Daarvoor zijn er te veel – deels onmeetbare – factoren van invloed op de zorginzet binnen de wijkverpleging. We kijken vier weken vooruit wat betreft de te voorspellen uren zorg, en vanwege de beoogde link met bekostigen en prikkelwerking gebruiken we geen informatie over andere gebeurtenissen in die periode. Het gaat dan om gebeurtenissen als: vakantie, herstel, overlijden, verpleeghuisopname, ziekenhuisopname, tijdelijke veranderingen in mantelzorg, veranderingen in fysieke of geestelijke toestand van de cliënt, fluctuaties in de beschikbaarheid van personeel bij de zorgaanbieder, het weer, griep/corona etc. Het wel meenemen van zulke toekomstige gebeurtenissen zal vermoedelijk voorspelkracht toevoegen, maar voor een prospectief case-mix model zijn deze niet werkbaar.

### ***Hoe zit het met de voorspelkracht van NANDA en Omaha?***

Voor de kenmerken uit NANDA en Omaha hebben we in eerder onderzoek op basis van random forest soortgelijke percentages gevonden als voor de case-mix vragenlijst [3,9]. Dit was echter voor individuele zorgaanbieders waardoor de verschillen tussen zorgaanbieders in hoe ze het classificatiesysteem gebruiken niet van invloed waren. Daarnaast worden in Nederland verschillende classificatiesystemen voor verpleegkundige diagnostiek naast elkaar gebruikt (Omaha, NANDA en InterRAI/NedRAI zijn de drie bekendste). Dit maakt de classificatiesystemen minder geschikt voor gebruik in een landelijk case-mix model.

### ***Waarom heeft het model voor formele + informele zorg een hogere voorspelkracht dan het model voor formele zorg?***

Het blijkt dat wanneer we kijken naar de gewogen combinatie formele en informele uren zorg, dat circa 65% van deze uren informeel zijn. Het is dus het verklaren van met name deze variatie die kan leiden tot een hoge R-kwadraat. In het model met enkel formele zorg wordt een andere variatie verklaard, namelijk die van de formele uren zorg. De modellen proberen dus verschillende variaties te verklaren, en zijn daarmee niet vergelijkbaar. Uit de lagere R-kwadraat voor het formele model kunnen we wel opmaken dat de variatie in de formele uren lastiger te verklaren is op basis van de case-mix vragenlijst dan de variatie in de optelsom van formele en informele uren zorg. Dit is in lijn met het gegeven dat de case-mix vragenlijst vraagt naar het functioneren van de cliënt, onafhankelijk van de ondersteuning door wijkverpleegkundige of mantelzorger.



In theorie zou het verklaren van de optelsom van beide zorgvormen kunnen leiden tot optimaal inzicht in welke cliënten een vergelijkbare zorgvraag hebben, en dus een vergelijkbare zorginzet nodig hebben. Echter, omdat het meten van de informele zorginzet met een vermoedelijk aanzienlijke meetfout gepaard gaat, én omdat gegeven een bepaalde zorgvraag, beide zorgvormen geen perfecte substituten zijn (vanwege eerder genoemde redenen), gaat dit in de praktijk niet op. Gegeven het hoofddoel om verschillen in formele zorguren te begrijpen, geven we daarom de voorkeur aan het model voor formele zorguren.

#### ***Kan de R-kwadraat nog beter worden?***

Het is mogelijk om verder te bouwen op de aanpak die hier gevolgd is: met een beperkte registratielast (een vragenlijst die enkele minuten kost om in te vullen) een maximaal resultaat te halen. Het blijkt dat er van de 11 vragen 6 voldoende zijn voor een optimaal voorspelresultaat. Dit betekent dat er vragen verwijderd zouden kunnen worden, waardoor er weer plek komt voor nieuwe items die mogelijk de voorspelkracht verder verhogen. Ook herformulering van bepaalde vragen (bijv. de maaltijd vraag) kan bijdragen aan een betere voorspelkracht. Dossier analyse van resterende variatie binnen de hier gevonden cliëntprofielen zou deze zoektocht kunnen faciliteren.

#### ***Kun je het model voor bekostiging gebruiken?***

Wanneer de financiële prikkel belangrijker wordt, neemt het risico op strategisch beantwoorden van vragen toe. In een dergelijke situatie moet je hele heldere definities hebben over wanneer iemand 'gedeeltelijk zelfstandig' of 'volledig niet zelfstandig' is ten aanzien van een bepaalde activiteit als wassen, kleden etc. Deze definities bestaan nu nog niet en zouden ontwikkeld en getest moeten worden. Ook is het meten van uitkomsten van zorg nodig om de prikkel tot verschraving van zorg binnen cliëntprofielen tegen te gaan.

#### ***Hoe zou je het model voor bekostiging kunnen gebruiken?***

Twee veel voorkomende toepassingen van cliëntkenmerken voor bekostiging zijn prestatiebekostiging en gebruik binnen de zorgcontractering. We beperken ons hier tot een beschrijving van deze toepassingen, en doen geen uitspraken over de wenselijkheid of geschiktheid van de huidige cliëntprofielen voor deze toepassingen.

Bij prestatiebekostiging is het gebruikelijk om prestaties te definiëren en hier een tarief of prijs aan te koppelen. Bij het bepalen van de wenselijkheid hiervan wordt vaak gekeken naar de kostenhomogeniteit, de mate van spreiding van kosten binnen de prestatie. Een veel gebruikte maat hierbij is de Coëfficiënt of Variation (de CV waarde). Een hoge kostenhomogeniteit hangt dan samen met lage spreiding, en een lage CV waarde. Merk op dat de CV waarde een relatieve maat is, deze is relatief ten opzichte van de gemiddelde kosten. Een CV waarde van 0,5 betekent dat bij voor een prestatie met 100 euro gemiddelde kosten, de bulk (95%) van de kosten tussen de 0 en 200 euro liggen<sup>5</sup>. Voor een prestatie met 1000 euro gemiddelde kosten, ligt de bulk van de kosten tussen de 0 en 2000 euro. In bijlage B5 is een tabel opgenomen met de CV waardes van de cliëntprofielen voor formele uren.

---

<sup>5</sup> Hierbij nemen we aan dat de variabele normaal verdeeld is, wat met zorgkosten / zorginzet vaak niet het geval is. De formule voor CV waarde is de standaard afwijking (standaarddeviatie) gedeeld door het gemiddelde.

Bij de zorgcontractering gaat om het maken van afspraken tussen zorgaanbieder en zorgverzekeraar. Deze afspraken zijn typisch op groepsniveau (bijvoorbeeld alle cliënten met wijkverpleging in een kalenderjaar). Hierbij kunnen benchmarks worden gebruikt, waarbij op basis van cliëntgebonden kenmerken met een statistisch model de verwachte kosten worden voorspeld, en afgezet tegen de werkelijke kosten. Op dit meer geaggregeerde niveau neemt de voorspelkracht doorgaans toe (voorbeelden zijn de zorgvraagzwaarte indicator in de ggz, en het risicovereveningsmodel voor zorgverzekeraars). De zorgprofielen zouden als voorspellers in dergelijke benchmarks opgenomen kunnen worden. Deze analyses zijn dan input voor de onderhandeling / gesprek tussen zorgaanbieder en zorgverzekeraar.

### ***Kun je nog meer met cliëntprofielen in de wijkverpleging?***

De focus ligt nu op het indelen van cliënten in cliëntprofielen voor bekostiging. Om deze cliëntprofielen optimaal te gebruiken voor leren en verbeteren is inzicht nodig in de verpleegkundige interventies / zorgpaden van cliënten. Het gaat dan om het gestandaardiseerd zichtbaar maken van wat er met een cliënt gebeurt in de wijk. Dit is te vergelijken met de manier waarop de DBC producten in de medisch-specialistische zorg zijn ontwikkeld (het DBC 2003 project, zie ook Westerdijk et al. (2012) [17]). Hier was de eenheid van analyse een traject dat een patiënt aflegde in het ziekenhuis. De focus lag op de (kosten veroorzakende) activiteiten (scans, operaties, ligdagen) tijdens de '**patient journey**', en het clusteren van patiënten met soortgelijke trajecten. Hiermee ontstaat inzicht in wat er gebeurt met de cliënt in de tijd. Daarmee kun je vervolgens ongewenste praktijkvariatie gaan terugdringen, onderzoek doen naar succesvolle interventies, etc. In de wijkverpleging lijkt hier nog veel onbenut potentieel te zijn.

Tot slot willen wij de bestuurders, medewerkers en in het bijzonder de wijkverpleegkundigen van de vier deelnemende zorgaanbieders bedanken voor het mogelijk maken van dit onderzoek.

# 4. Referenties

1. Zorgverzekeraars Nederland. (2016). ZN Verdiepingsnotitie Doelgroepen, d.d. 21 oktober 2016, versie 1.0.
2. Zorgverzekeraars Nederland. (2018). ZN Doelgroepenregistratie schema en beslisboom, d.d. 01 juli 2018, versie 2.0.
3. De Korte, M.H., Verhoeven, G.S., Elissen, A.M.J., Metzelthin, S.F., Ruwaard, D. & Mikkers, M.C. (2020). Using machine learning to assess the predictive potential of standardized nursing data for home healthcare case-mix classification. *The European Journal of Health Economics* 2020. doi: <https://doi.org/10.1007/s10198-020-01213-9>.
4. Van den Bulck, A.O.E., De Korte, M.H., Elissen, A.M.J., Metzelthin, S.F., Mikkers, M.C., & Ruwaard, D. (2020). A systematic review of case-mix models for home health care payment: Making sense of variation. *Health Policy*, 124(2): 121-132. doi: <https://doi.org/10.1016/j.healthpol.2019.12.012>
5. Van den Bulck, A.O.E., Metzelthin, S.F., Elissen, A.M.J., Stadlander, M.C., Stam, J.E., Wallinga, G. & Ruwaard, D. Which client characteristics predict home-care needs? Results of a survey study among Dutch home-care nurses. *Health and Social Care in the Community*, 2018;27(1): 93-104.
6. Elissen, A.M.J., Verhoeven, G.S., De Korte, M.H., Van den Bulck, A.O.E., Metzelthin, S.F., Van der Weij, L.C., Stam, J., Ruwaard, D. & Mikkers, M.C. (2020). Development of a case-mix classification to predict costs of home care in the Netherlands: a study protocol. *BMJ Open*. 2020; 10(2): e035683. doi: 10.1136/bmjopen-2019-035683
7. PwC. (2017). Onderzoek tariefherijking verpleging en verzorging, 5 april 2017. Zie: [https://puc.overheid.nl/nza/doc/PUC\\_3582\\_22/1/](https://puc.overheid.nl/nza/doc/PUC_3582_22/1/)
8. Pearl, J. & Mackenzie, D. (2018). *The Book of Why*. New York: Basic Books.
9. Nederlandse Zorgautoriteit. Data-analyses met betrekking tot cliëntgroepen in de wijkverpleging, februari 2019. Zie: [https://puc.overheid.nl/nza/doc/PUC\\_268372\\_22/1/](https://puc.overheid.nl/nza/doc/PUC_268372_22/1/)
10. James, G., Witten, D., Hastie T. & Tibshirani, R. (2013). *An introduction to statistical learning: with applications in R*. New York: Springer

11. Kuhn, M. (2019). caret: Classification and Regression Training. The Comprehensive R Archive Network. <https://CRAN.R-project.org/package=caret>.
12. Terminologiecentrum Nictiz, SNOMED CT. **Gebruikte pagina's:**  
<https://terminologie.nictiz.nl/art-decor/snomed-ct?conceptId=262526004> &  
<https://terminologie.nictiz.nl/art-decor/snomed-ct?conceptId=399912005>
13. Kieft, R., Vreeke, E. M., de Groot, E. M., de Graaf-Waar, H. I., van Gool, C. H., Koster, N., Ten Napel, H., Francke, A. L., & Delnoij, D. (2018). Mapping the Dutch SNOMED CT subset to Omaha System, NANDA International and International Classification of Functioning, Disability and Health. *International journal of medical informatics*, 111, 77–82.  
<https://doi.org/10.1016/j.ijmedinf.2017.12.025>
14. Parsons, M., Rouse, P., Sajtos, L., Harrison, J., Parsons, J. & Gestro, L. (2018). Developing and utilising a new funding model for home-care services in New Zealand. *Health and Social Care in the Community* 2018; 26(3): 345-355.
15. Gupta Strategists. (2016). Onderzoek bekostiging wijkverpleging. Eindrapportage, januari 2016.
16. Koster, N.M., Harmsen, J., Veldkamp, B.P. & Van der Palen, J. (2017). Client characteristics as predictors of care intensity in home health care. University of Twente.
17. Westerdijk, M., Zuurbier, J., Ludwig, M., & Prins, S. (2012). Defining care products to finance health care in the Netherlands. *The European Journal of Health Economics*, 13(2), 203–221. <https://doi.org/10.1007/s10198-011-0302-6>

# Bijlage A:

## Onderzoeksverantwoording

### A1. Vergelijking met studieprotocol

Ten opzichte van het van te voren opgestelde studieprotocol zijn er enkele verschillen in hoe de analyse is uitgevoerd. Het belangrijkste verschil is dat lineaire regressie is toegevoegd als **methode**. Daarnaast heeft er voor de random forest nog geen 'recursive feature elimination' plaatsgevonden, dit zou de voorspelkracht nog wat kunnen verhogen doordat er minder overfitting plaats vindt.

Een ander verschil is dat nog niet alle geplande analyses zijn uitgevoerd. Belangrijkste hiervan zijn de verdiepende analyse op non-response, en de 'single tree approximation' (STA), waarbij we een beslisboom maken op de voorspellingen van een random forest machine learning model.

### A2. Gegevensverzameling en verwerking

Voor de gegevensverzameling is de case-mix vragenlijst ingebouwd in het ECD van de vier zorgaanbieders. In samenspraak met een ECD-specialist is een aanleverspecificatie<sup>6</sup> opgesteld voor de gehele inhoud van de gegevensleveringen. Samengevat gaat het om de volgende gegevens:

- Demografische gegevens
- Case-mix vragenlijsten
- NANDA/Omaha vragenlijsten
- Zorgplannen
- Geregistreerde uren voor elke cliënt

Deze gegevens zijn aangeleverd voor alle cliënten met een Zvw legitimatie en met tenminste één registratie vanaf 01-06-2019. Daarnaast zijn cliënten die hebben aangegeven niet te willen deelnemen aan het NZa onderzoek uitgesloten.

De ECD-specialist heeft voor elke zorgaanbieder SQL queries geschreven die enkel de benodigde gegevens uit het ECD extraheert. Voor elke zorgaanbieder hebben een aantal testaanleveringen plaatsgevonden om de gegevens te controleren en de queries waar nodig aan te passen. Vervolgens heeft elke zorgaanbieder drie gegevensaanleveringen gedaan: in september/oktober 2019, in januari 2020 en in april 2020. De zorgaanbieders hebben de data via het beveiligd uitwisselportaal van de NZa aangeleverd.

---

<sup>6</sup> De aanleverspecificatie is als bijlage bij het studieprotocol beschikbaar. Zie: <https://bmjopen.bmj.com/content/bmjopen/10/2/e035683/DC3/embed/inline-supplementary-material-3.pdf?download=true>

In oktober/november zijn we bij alle vier de zorgaanbieders langs gegaan om o.a. de kwaliteit en betekenis van de data te bespreken. Daarna is voor elke nieuwe aanlevering een rapportage aangeleverd aan de zorgaanbieders met beschrijvende analyses over de aangeleverde data. Op basis hiervan konden de zorgaanbieders aangeven of ze de getallen herkenden, en waar mogelijk nog een probleem zat. Dit was daarmee een belangrijk onderdeel van de gegevensverzameling.

Daarnaast is het belangrijk gebleken om de ECD data naast andere beschikbare databronnen te leggen, zoals de declaraties uit Vektis. In deze analyse hebben we voor elke zorgaanbieder de geleverde uren en cliëntaantallen uit het ECD vergeleken met Vektis. Als deze vergelijking goed overeenkomt, is dat een indicator dat de data volledig is. Andersom geldt dat weinig overeenkomst betekent dat er mogelijk iets mist in de ECD data.

### **A3. Details proces van ruwe data naar onderzoeksbestand**

#### ***Beschrijving aanpak***

Voor het modelleren hebben we een onderzoeksbestand nodig met op cliëntniveau de gewogen uren formele en informele zorg (de te voorspellen variabelen) en de beschikbare cliëntkenmerken (de voorspellers).

Hiervoor hebben we de verzameling ingevulde case-mix vragenlijsten als startpunt genomen. Aan elke case-mix vragenlijst hebben we vervolgens uren zorg en de kenmerken uit de verpleegkundige classificatiesystemen gekoppeld.

Aan deze koppelingen zijn keuzes verbonden. Deze keuzes hebben potentieel impact op de omvang en voorspelkracht van het uiteindelijke onderzoeksbestand. Om die reden hebben wij niet één set keuzes gemaakt, maar hierin gevarieerd om de impact te kunnen bepalen.

Tijd speelt een belangrijke rol in alle koppelingen. Ter illustratie: aan de case-mix vragenlijst behoren drie datumvelden: 1) de datum van aanmaak, 2) de datum waarop de vragenlijst op actueel wordt gezet en 3) de datum waarop de vragenlijst als laatste is bijgewerkt. We hebben in **de data gezien dat 'datum actueel' en 'datum laatst bijgewerkt' soms ver na de aanmaakdatum van de case-mix vragenlijst liggen.** In sommige gevallen ontvangt de cliënt dan al geen zorg meer. Deze datumvelden lijken dus geen goede weergave van het moment waarop de vragenlijst is ingevuld.

Zo zijn er meerdere parameters waar dergelijke keuzes een rol spelen. We lichten de andere parameters hieronder toe.

#### ***Koppeling case-mix vragenlijst en de geleverde uren zorg***

We willen de uren zorg ná de case-mix vragenlijst voorspellen. Hiervoor moeten we dus de geleverde uren zorg na datum van de case-mix vragenlijst optellen. Dit kan direct vanaf de dag na afname case-mix vragenlijst, maar bijvoorbeeld ook pas vanaf 2 dagen, of vanaf 7 dagen. Het idee hier achter is dat het even zou kunnen duren voor de zorg volledig op gang is zoals geïndiceerd voor de cliënt.

### ***Datum van NANDA / Omaha / zorgplan***

Hiervoor geldt hetzelfde als voor de case-mix vragenlijst, namelijk dat er verschillende datumvelden beschikbaar zijn. Voor NANDA gaat het om datum aanmaak, datum actueel en datum laatst bijgewerkt. Voor Omaha enkel om datum aanmaak en datum laatst bijgewerkt. Voor het zorgplan is er een aanmaak datum, maar ook de begindatum welke de wijkverpleegkundigen handmatig kunnen instellen.

### ***Koppeling NANDA / Omaha / zorgplan***

Voor een cliënt wordt regelmatig een nieuwe NANDA/Omaha vragenlijst ingevuld, en ook zorgplannen kunnen regelmatig wijzigen. Het is van belang dat we de meest waarschijnlijk 'geldende' kenmerken uit NANDA/Omaha en het zorgplan koppelen aan de case-mix vragenlijst. Hierin zijn verschillende varianten mogelijk:

- meest recente vóór de case-mix vragenlijst
  - variant: mag max. 3 maanden van de case-mix vragenlijst afliggen
  - variant: mag max. 6 maanden van de case-mix vragenlijst afliggen.
- meest recente vóór of maximaal 7 dagen na de case-mix vragenlijst

### ***Resultaten***

We hebben eerst de impact bepaald van de verschillende koppelingen op het aantal observaties. Zoals al aangegeven, leidt de aanmaak datum voor de case-mix vragenlijst tot de meeste geïnccludeerde vragenlijsten. Variëren in de tussenpoos tussen de case-mix vragenlijst en de geleverde uren zorg heeft weinig effect op het aantal observaties. Er is nauwelijks verlies bij het vergroten van deze tussenpoos van 1 naar 2 of naar 7 dagen na de case-mix vragenlijst. Het vergroten van dit aantal dagen leidt ook niet tot een aanmerkelijk hogere voorspelkracht.

Het koppelen van NANDA / Omaha en de zorgplannen aan de case-mix vragenlijst zorgt voor een verlaging van het aantal observaties. Dit komt doordat niet voor alle cliënten met een case-mix vragenlijst ook een NANDA of Omaha vragenlijst beschikbaar is. Afhankelijk van de wijze van koppelen varieert het verlies ten opzichte van het totaal aantal observaties tussen de 77 en 98 procent. De impact op het aantal observaties is voor de Omaha zorgaanbieders wat lager dan voor **de NANDA zorgaanbieders. Het kiezen van 'datum laatst bijgewerkt' of 'datum actueel' en het begrenzen van de NANDA/Omaha vragenlijsten op max. 3 of 6 maanden leidt tot het meeste dataverlies. Voor het zorgplan leidt 'datum aanmaak' tot iets minder dataverlies dan de begindatum van het zorgplan.** Aangezien de keuzes rondom koppelen voor NANDA/Omaha en het zorgplan niet tot grote verschillen in voorspelkracht leiden, kiezen we voor koppelingen die de meeste observaties behouden.

Het onderzoeksbestand dat we uiteindelijk hebben gebruikt voor het modelleren is gebaseerd op de volgende keuzes:


- Datum case-mix vragenlijst: datum van aanmaak
- Koppeling case-mix / uren: dag na afname case-mix vragenlijst
- Datum NANDA/Omaha: datum van aanmaak
- Datum zorgplan: datum van aanmaak
- Koppeling NANDA/Omaha en zorgplan: meest recente vóór of maximaal 7 dagen na de case-mix vragenlijst

## A4. Beschrijving onderzoeksbestand

In het onderzoeksbestand dat wordt gebruikt in de voorspelmodellen is elk record één case-mix vragenlijst. De te voorspellen variabelen en de cliëntkenmerken die we mee willen nemen als voorspellers zijn aan dit record gekoppeld conform de beschrijving in paragraaf A3 van deze bijlage.

De meeste vragen uit de case-mix vragenlijst zijn als geordende vragen meegenomen in de analyses. Uitzondering hierop is de vraag over verwacht verloop: de antwoordopties op deze vraag zijn als dummy variabelen meegenomen in het onderzoeksbestand. De andere uitzondering is de medicatie vraag. Deze vraag is binair gemaakt: wel / niet zelfstandige inname van medicatie. De verdeling over de antwoordopties van de case-mix vragenlijst is weergegeven in onderstaande figuur. Meestal worden bij de geordende vragen lichtere antwoordopties vaker gekozen dan zwaardere.

**Figuur 25. Verdeling antwoordopties case-mix vragenlijst in onderzoeksbestand**



De Omaha- en NANDA kenmerken zijn als dummy variabelen meegenomen in het onderzoeksbestand. Voor Omaha gaat het hierbij om de geregistreerde aandachtsgebieden en signalen en symptomen. Voor NANDA gaat het om de geregistreerde diagnoses, bepaalde kenmerken en samenhangende factoren. Er is geen hiërarchie aangebracht in deze verschillende type kenmerken; elk kenmerk wordt als voorspeller meegenomen. Wel hebben we alleen Omaha- of NANDA-kenmerken geselecteerd die tenminste bij 1% van de cliënten voor kwam.



De tabel hieronder geeft de overige specificaties weer van het gebruikte onderzoeksbestand. Waar het gaat om de NANDA- en Omaha-kenmerken gaat het telkens om twee van de vier aanbieders.

Kenmerk	Klasse	gemiddelde $\pm$ sd of N (%)
Formele uren zorg (gewogen)		14 $\pm$ 23
Informele uren zorg (gewogen)		28 $\pm$ 55
Leeftijd		78 $\pm$ 12
Geslacht	Man	1816 (36.3)
	Vrouw	3183 (63.7)
ZN-doelgroep	Langetermijn, somatisch	2984 (59.7)
	Kortetermijn, kwetsbaar	758 (15.2)
	Kortetermijn, ziekenhuis nazorg	623 (12.5)
	Langetermijn, psychogeriatrisch	504 (10.1)
	Palliatief	109 (2.2)
	Preventie	21 (0.4)
	Kind	0 (0.0)
NANDA anamnese	Diagnosen	4 $\pm$ 3
	Bepalende kenmerken	14 $\pm$ 13
	Samenhangende factoren	6 $\pm$ 7
NANDA zorgplan	Diagnosen	2 $\pm$ 1
Omaha anamnese	Aandachtsgebieden	3 $\pm$ 2
	Signalen en symptomen	5 $\pm$ 4
Omaha zorgplan	Aandachtsgebieden	2 $\pm$ 2

## A5. Voorspelkracht van de modellen: CPM, MAPE en RMSE

In de rapportage vermelden we steeds de R-kwadraat waarden van de modellen. Voor de R-kwadraat gebruiken we default methode van het 'caret' package, deze berekent het kwadraat van de correlatie van de voorspelde en werkelijke waarde. Deze waarde kan nooit kleiner dan nul zijn, in tegenstelling tot de methode die bij reguliere regressie modellen standaard gebruikt wordt (zie: <http://topepo.github.io/caret/measuring-performance.html#reg>).

We maken ook gebruik van een aantal andere maatstaven om te beoordelen hoe goed een model voorspelt. Dit zijn:

- de Mean Absolute Prediction Error (MAPE)
- de Root Mean Squared Error (RMSE)
- de Cummings' Prediction Measure (CPM)

Al deze maatstaven kijken naar het verschil tussen de werkelijke waarden en de voorspelde waarden. Net als de R-kwadraat is de CPM een relatieve maat. De MAPE en RMSE zijn uitgedrukt in de eenheid van de uitkomstvariabele (uren). Zowel de RMSE als de R-kwadraat kwadrateren de verschillen tussen de voorspelde en werkelijke waarden, en geven op die manier meer gewicht aan extreme waarden. Hierdoor kunnen een klein aantal grote voorspelfouten veel invloed hebben op hun waarde. Voor de MAPE en CPM geldt deze gevoeligheid voor uitschieters niet, deze maten zijn gebaseerd op de absolute verschillen tussen de werkelijke en voorspelde uitkomst. Alle voorspelfouten worden daarmee gelijk gewogen.

**In bijlage B 'Extra analyses' rapporteren we alle resultaten: zowel R-kwadraat als CPM, MAPE en RMSE voor alle modellen die in de rapportage en de bijlagen worden getoond.**

## **A6. Methoden per figuur**

### Figuur 4: Verdeling antwoordopties case-mix vragenlijst

Alle vragenlijsten met een status *Actueel* of *Gearchiveerd* zijn meegenomen. Vragenlijsten die nog niet actueel zijn gemaakt, worden niet getoond. De volledige vragen en antwoordopties behorend **bij deze figuur zijn terug te vinden in bijlage C 'Case-mix vragenlijst'**.

### Figuur 5: netwerk plot van correlaties tussen de case-mix vragen

Voor dit figuur hebben we bewust gekozen voor Spearman correlatie coëfficiënten die dichter op de data blijven, en niet voor een meer modelmatige aanpak met tetra / polychorische correlatie coëfficiënten.

### Figuur 6: Aandeel cliënten per doelgroep per maand, gemiddeld over pilotperiode

Voor deze figuur zijn alle in de pilot geïnccludeerde cliënten meegenomen met een ZN-doelgroep registratie en minstens één zorgmoment bij de zorgaanbieders in de periode juni t/m december 2019. De percentages zijn gebaseerd op het gemiddeld aantal cliënten per doelgroep over de kalendermaanden van de pilot.

### Figuur 7: Verdeling uren zorg per maand over functieniveaus

De figuur is gebaseerd op alle uren records van in de pilot geïnccludeerde cliënten van de periode juni t/m december 2019. Ca. 4% van de records had een onbekende functie. Aan deze records is functieniveau *Certified Nursing assistant (EQF 3)* toegekend (gewicht 1,00). Uren geleverde zorg per maand per (vertaald) functieniveau is gemiddeld over de kalendermaanden van de pilot.

### Figuur 8: Gewogen uren zorg in gemiddelde kalendermaand, per functieniveau

De figuur is gebaseerd op dezelfde gegevens als figuur 7, maar hier worden de gewogen uren zorg getoond.

### Figuur 11: CART en random forest resultaten (formele uren)

De figuur toont de R-kwadraat voorspelresultaten voor formele zorginzet op basis van CART-beslisbomen en random forest voor verschillende sets van voorspellers:

- ZN-doelgroepen
- Case-mix vragenlijst + wond/decubitus kenmerk
- Case-mix vragenlijst + wond/decubitus kenmerk + mantelzorgvraag + leeftijd/geslacht
- ZN-doelgroepen + case-mix vragenlijst + wond/decubitus kenmerk + mantelzorgvraag + leeftijd/geslacht

De beslisboom analyses zijn tien keer herhaald met telkens een andere verdeling van data over de cross-validatie folds (10-fold cross validation met 10 repeats). De spreiding binnen deze repeats is weergegeven met de zwarte lijn.

### Figuur 12: CART en random forest resultaten bij toevoegen informele uren als voorspeller (formele uren)

De figuur toont de R-kwadraat voorspelresultaten voor formele zorginzet op basis van CART-beslisbomen en random forest voor twee sets van voorspellers:

- Case-mix vragenlijst + wond/decubitus kenmerk
- Case-mix vragenlijst + wond/decubitus kenmerk + de geschatte informele uren zorg

De beslisboom analyses zijn tien keer herhaald met telkens een andere verdeling van data over de cross-validatie folds (10-fold cross validation met 10 repeats). De spreiding binnen deze repeats is weergegeven met de zwarte lijn.

### Figuur 13: Beslisboom formele uren

De getoonde beslisboom heeft als input een dataset met alle cliënten uit het onderzoeksbestand (N = 4999). Alle zorgaanbieders zijn meegenomen en er heeft geen exclusie plaatsgevonden (bijvoorbeeld op basis van een onder-/bovengrens voor het aantal uren ontvangen zorg in de vier weken na invullen van de case-mix vragenlijst). Het splitsen van de data stopt als bij een split een cliëntprofiel ontstaat met minder dan 30 cliënten. Bij het terugsnijden hebben we gekozen voor de MAE als maat voor de voorspelkracht, en het tolerantie percentage is 1.5%.

In de getoonde beslisboom zijn de beslisregels samengevat weergegeven. In onderstaande tabel is precies te vinden hoe de beslisregels zich verhouden tot de case-mix vragenlijst.

Beslisregel	Case-mix vraag	Score voor JA
Cliënt krijgt palliatief terminale zorg?	Verwachte verloop (in de komende maand)	Ja bij antwoord 'De cliënt ontvangt palliatief terminale zorg en heeft een levensverwachting van minder dan 3 maanden.'
Cliënt kan zich zelfstandig aan en uit kleden?	Aan- en uitkleden	Ja bij antwoord 'De cliënt kan zich zelfstandig aan- en uitkleden.'
Cliënt neemt zelfstandig medicatie?	Innemen van medicatie	Ja bij antwoord 'De cliënt neemt zelfstandig medicatie.'
Cliënt heeft volledige hulp nodig bij het wassen?	Wassen en douchen	Ja bij antwoord 'De cliënt moet volledig geholpen worden door derden om zich te wassen/douchen.'
Cliënt zal naar verwachting verslechteren?	Verwachte verloop (in de komende maand)	Ja bij antwoord 'De toestand en/of zelfstandigheid van de cliënt zal naar verwachting verslechteren.'
Cliënt is incontinent?	Continentie	Ja bij antwoord <b>anders dan</b> 'De cliënt is volledig continent, zowel voor urine als voor ontlasting.'
Cliënt is incontinent voor urine en ontlasting?	Continentie	Ja bij antwoord 'De cliënt is incontinent voor urine én ontlasting en/of gebruikt hier hulpmiddelen voor.'

#### Figuur 14: Percentages cliënten en percentages uren (formeel) per cluster

De aantallen cliënten en het gemiddeld aantal uren formele zorg worden per cluster in de beslisboom vermeld. Deze figuur toont de percentages per cluster van alle cliënten en van alle gewogen zorguren.

#### Figuur 15: Spreiding en gemiddelde van de beslisboom groepen voor formele uren zorg

Dit figuur toont de histogrammen van de formele uren per groep van de beslisboom. De rode lijn is het gemiddelde, en komt overeen met de gemiddelden per groep die in de beslisboom staan vermeld.

#### Figuur 16: Percentages cliënten en percentages uren (formeel) per zorgaanbieder, per cluster

De berekende beslisboom voor formele uren is opnieuw op de oorspronkelijke dataset toegepast. Daardoor kunnen we de resultaten ook splitsen op kenmerken die geen input vormden bij het berekenen van de beslisboom, zoals per zorgaanbieder. In deze figuur worden aantallen en urengemiddeldes per zorgaanbieder getoond.

#### Figuur 17: Gemiddelde formele uren per cliënt per cluster

Deze figuur toont het gemiddeld aantal formele uren per zorgaanbieder en het gemiddelde over alle zorgaanbieders. Alleen clusters die bij elke zorgaanbieder minimaal 35 cliënten bevatten worden getoond. Om een idee te krijgen van de spreiding binnen elk cluster worden error bars getoond. Er is gebruik gemaakt van bootstrapping om de spreiding binnen elk cluster te schatten. De error bars in deze figuur tonen de geschatte gemiddeldes tussen het 2,5<sup>e</sup> en 97,5<sup>e</sup> percentiel bij 1000 herhalingen.

#### Figuur 18: CART en random forest resultaten op selecties van de data (formeel uren, case-mix voorspellers)

De figuur toont de R-kwadraat voorspelresultaten voor formele zorginzet op basis van CART-beslisbomen en random forest voor **dezelfde** set voorspellers, namelijk de case-mix vragenlijst + wond/decubitus kenmerk. Wat varieert, is de data waarmee het model is gebouwd. Deze selecties op de data zijn:

- Alleen cliënten met meer dan 5 contactmomenten
- Alleen niet-palliatieve cliënten
- Alleen cliënten met minder dan 85 uur formele zorg per maand

De beslisboom analyses zijn tien keer herhaald met telkens een andere verdeling van data over de cross-validatie folds (10-fold cross validation met 10 repeats). De spreiding binnen deze repeats is weergegeven met de zwarte lijn.

#### Figuur 19: Regressie (‘ordinary least squares) en random forest resultaten (formeel uren)

De figuur laat de voorspelresultaten zien voor formele zorginzet van regressie en random forest modellen voor dezelfde sets voorspellers als in figuur 11. De regressie analyses zijn tien keer herhaald met telkens een andere verdeling van data over de cross-validatie folds (10-fold cross validation met 10 repeats). De spreiding binnen deze repeats is weergegeven met de zwarte lijn.

#### Figuur 21: Formele uren zijn 35% van de gewogen optelsom van uren zorg

Voor dit figuur is het totaal aan uren zorg in het onderzoeksbestand bepaald. Het gaat hier om de gewogen uren. Vervolgens hebben we berekend welk deel hiervan de gewogen formele uren zorg zijn.

## Figuur 22: CART en random forest resultaten (formele en informele uren)

De figuur toont de R-kwadraat voorspelresultaten voor de gewogen optelsom van formele en informele zorginzet op basis van CART-beslisbomen en random forest voor verschillende sets van voorspellers:

- ZN-doelgroepen
- Case-mix vragenlijst + wond/decubitus kenmerk
- Case-mix vragenlijst + wond/decubitus kenmerk + mantelzorger vraag + leeftijd/geslacht
- ZN-doelgroepen + case-mix vragenlijst + wond/decubitus kenmerk + mantelzorger vraag + leeftijd/geslacht

De beslisboom analyses zijn tien keer herhaald met telkens een andere verdeling van data over de cross-validatie folds (10-fold cross validation met 10 repeats). De spreiding binnen deze repeats is weergegeven met de zwarte lijn.

## Figuur 23: Beslisboom formele en informele uren

De getoonde beslisboom heeft als input een dataset met alle cliënten uit het onderzoeksbestand (N = 4999). Alle zorgaanbieders zijn meegenomen en er heeft geen exclusie plaatsgevonden (bijvoorbeeld op basis van een onder-/bovengrens voor het aantal uren ontvangen zorg in de vier weken na invullen van de case-mix vragenlijst). Het splitsen van de data stopt als bij een split een cliëntprofiel ontstaat met minder dan 30 cliënten. Bij het terugsnijden hebben we gekozen voor de MAE als maat voor de voorspelkracht, en het tolerantie percentage is 1.5%.

In de getoonde beslisboom zijn de beslisregels samengevat weergegeven. In onderstaande tabel is precies te vinden hoe de beslisregels zich verhouden tot de case-mix vragenlijst.

Beslisregel	Case-mix vraag	Score voor JA
Cliënt kan zelfstandig naar het toilet?	Gebruik maken van het toilet	Ja bij antwoord 'De cliënt kan zelfstandig gebruik maken van het toilet bedpan of urinaal.'
Cliënt kan zich zelfstandig aan en uit kleden?	Aan- en uitkleden	Ja bij antwoord 'De cliënt kan zich zelfstandig aan- en uitkleden.'
Cliënt krijgt palliatief terminale zorg?	Verwachte verloop (in de komende maand)	Ja bij antwoord 'De cliënt ontvangt palliatief terminale zorg en heeft een levensverwachting van minder dan 3 maanden.'
Cliënt heeft het cognitieve vermogen om zelfstandig of met hulp adequate beslissingen te nemen?"	Cognitieve vaardigheden voor de dagelijkse besluitvorming	Ja bij antwoord 'De cliënt heeft geen cognitieve beperking: hij/zij kan volledig zelfstandig adequate beslissingen nemen.' of 'De cliënt heeft vanwege (een verdenking op) een cognitieve beperking gedeeltelijke hulp van derden nodig (bijv. aansporing of toezicht) om adequate beslissingen te nemen.'
Cliënt kan zelfstandig eten en drinken?	Eten en drinken	Ja bij antwoord 'De cliënt kan zelfstandig eten en drinken.'
Cliënt neemt zelfstandig medicatie?	Innemen van medicatie	Ja bij antwoord 'De cliënt neemt zelfstandig medicatie.'
Cliënt moet volledig geholpen worden bij toilet?	Gebruik maken van het toilet	Ja bij antwoord 'De cliënt moet volledig geholpen worden door derden om gebruik te maken van het toilet, bedpan of urinaal.'

Cliënt zal naar verwachting verslechteren?	Verwachte verloop (in de komende maand)	<b>Ja bij antwoord 'De toestand en/of zelfstandigheid van de cliënt zal naar verwachting verslechteren.'</b>
--	---	--

#### Figuur 24: Regressie (ols) en random forest resultaten (formele en informele uren)

De figuur laat de voorspelresultaten zien voor de gewogen optelsom voor formele en informele zorginzet van regressie en random forest modellen voor dezelfde sets voorspellers als in figuur 22. De regressie analyses zijn tien keer herhaald met telkens een andere verdeling van data over de cross-validatie folds (10-fold cross validation met 10 repeats). De spreiding binnen deze repeats is weergegeven met de zwarte lijn.

# Bijlage B: Extra analyses

## B1. Alle modelresultaten

Resultaten formele modellen zoals in figuur 11 en figuur 19

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
ZN doelgroepen	4999	random forest	10,6	10,6	10,6	3,6	3,6	3,6	21,3	21,3	21,3	9,3	9,3	9,3
ZN doelgroepen	4999	cart	10,6	10,7	10,7	2,4	2,6	2,7	20,9	21,2	21,4	8,6	10,1	11,7
ZN doelgroepen	4999	ols	10,5	10,5	10,5	3,8	4,0	4,1	20,8	21,1	21,3	9,7	11,2	12,7
Casemix	4999	random forest	9,3	9,3	9,3	15,0	15,0	15,0	19,2	19,2	19,2	25,5	25,5	25,5
Casemix	4999	cart	9,5	9,5	9,6	12,1	12,6	13,2	19,4	19,6	19,9	17,5	20,9	24,1
Casemix	4999	ols	9,3	9,4	9,4	14,1	14,3	14,5	19,0	19,2	19,3	21,4	24,7	26,7
Casemix+	4999	random forest	9,3	9,3	9,3	15,3	15,3	15,3	19,1	19,1	19,1	26,0	26,0	26,0
Casemix+	4999	cart	9,6	9,7	9,8	10,7	11,7	12,3	19,5	19,8	20,0	13,9	19,2	23,9
Casemix+	4999	ols	9,4	9,4	9,4	13,9	14,1	14,4	19,1	19,2	19,4	21,4	24,6	26,5
Casemix+ & ZN doelgroepen	4999	random forest	9,2	9,2	9,2	15,5	15,5	15,5	19,1	19,1	19,1	26,2	26,2	26,2
Casemix+ & ZN doelgroepen	4999	cart	9,6	9,7	9,8	10,7	11,7	12,3	19,5	19,8	20,0	13,9	19,2	23,9
Casemix+ & ZN doelgroepen	4999	ols	9,4	9,4	9,4	13,8	14,0	14,3	19,1	19,3	19,4	21,1	24,4	26,3

Resultaten formele modellen zoals in figuur 12

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	4999	random forest	9,3	9,3	9,3	15,0	15,0	15,0	19,2	19,2	19,2	25,5	25,5	25,5
Casemix	4999	cart	9,5	9,5	9,6	12,1	12,6	13,2	19,4	19,6	19,9	17,5	20,9	24,1
Casemix & informele uren	4999	random forest	9,2	9,2	9,2	15,7	15,7	15,7	19,0	19,0	19,0	27,2	27,2	27,2
Casemix & informele uren	4999	cart	9,6	9,6	9,7	10,9	11,8	12,2	19,4	19,7	20,0	15,2	19,7	23,0

## Resultaten formele modellen zoals in figuur 18

Label selectie	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Alle cliënten	4999	random forest	9,3	9,3	9,3	15,0	15,0	15,0	19,2	19,2	19,2	25,5	25,5	25,5
Alle cliënten	4999	cart	9,5	9,5	9,6	12,1	12,6	13,2	19,4	19,6	19,9	17,5	20,9	24,1
Excl. palliatief	4877	random forest	7,8	7,8	7,8	13,1	13,1	13,1	13,2	13,2	13,2	16,9	16,9	16,9
Excl. palliatief	4877	cart	8,0	8,0	8,0	10,3	10,8	11,0	13,4	13,5	13,6	11,7	13,0	13,6
Excl. palliatief / >85u per maand	4850	random forest	7,1	7,1	7,1	13,1	13,1	13,1	10,0	10,0	10,0	20,7	20,7	20,7
Excl. palliatief / >85u per maand	4850	cart	7,2	7,2	7,2	11,3	11,5	11,8	10,2	10,2	10,2	16,6	17,0	17,2
Excl. palliatief / >85u per maand / <5 contactmomenten	4287	random forest	7,1	7,1	7,1	12,9	12,9	12,9	10,0	10,0	10,0	20,5	20,5	20,5
Excl. palliatief / >85u per maand / <5 contactmomenten	4287	cart	7,2	7,3	7,3	10,8	11,2	11,5	10,2	10,2	10,3	15,8	16,7	17,6
Excl. <5 contactmomenten	4423	random forest	9,6	9,6	9,6	15,3	15,3	15,3	19,9	19,9	19,9	27,2	27,2	27,2
Excl. <5 contactmomenten	4423	cart	9,7	9,8	9,8	12,7	13,3	13,7	19,9	20,3	20,5	18,4	22,8	26,3

## Resultaten informele modellen zoals in figuur 22 en figuur 24

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
ZN doelgroepen	4999	random forest	33,7	33,7	33,7	5,1	5,1	5,1	59,6	59,6	59,6	8,2	8,2	8,2
ZN doelgroepen	4999	cart	33,8	33,8	33,8	4,5	4,6	4,7	59,6	59,7	59,9	6,9	7,3	7,8
ZN doelgroepen	4999	ols	33,6	33,6	33,6	5,2	5,3	5,3	59,4	59,5	59,7	7,6	8,0	8,5
Casemix	4999	random forest	26,8	26,8	26,8	24,4	24,4	24,4	50,7	50,7	50,7	33,4	33,4	33,4
Casemix	4999	cart	27,6	27,7	27,8	21,6	21,8	22,1	51,4	51,6	51,8	29,8	30,6	31,2
Casemix	4999	ols	26,7	26,8	26,8	24,3	24,4	24,5	50,4	50,6	50,7	32,7	33,2	33,9
Casemix+	4999	random forest	25,4	25,4	25,4	28,4	28,4	28,4	49,3	49,3	49,3	37,0	37,0	37,0
Casemix+	4999	cart	26,7	26,9	27,0	23,9	24,1	24,6	50,7	50,9	51,1	31,6	32,4	33,1
Casemix+	4999	ols	25,6	25,6	25,6	27,6	27,8	27,9	48,8	49,0	49,1	37,1	37,5	38,0
Casemix+ & ZN doelgroepen	4999	random forest	25,4	25,4	25,4	28,3	28,3	28,3	49,3	49,3	49,3	37,0	37,0	37,0
Casemix+ & ZN doelgroepen	4999	cart	26,7	26,9	27,0	23,9	24,1	24,6	50,7	50,9	51,1	31,6	32,4	33,1
Casemix+ & ZN doelgroepen	4999	ols	25,6	25,6	25,7	27,4	27,6	27,8	48,8	49,0	49,1	36,9	37,3	37,9

## Resultaten modellen zoals in figuur 26

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	2827	random forest	9,7	9,7	9,7	19,0	19,0	19,0	20,4	20,4	20,4	31,8	31,8	31,8
Casemix	2827	cart	9,9	10,0	10,0	15,4	16,2	16,9	20,6	20,8	21,2	19,6	28,1	32,9
Casemix plus NANDA totaal	2827	random forest	9,8	9,8	9,8	17,6	17,6	17,6	20,8	20,8	20,8	29,6	29,6	29,6
Casemix plus NANDA totaal	2827	cart	10,2	10,2	10,2	13,6	14,3	15,1	20,7	21,0	21,3	18,9	27,2	32,5
Casemix plus NANDA zorgplan	2827	random forest	9,6	9,6	9,6	19,8	19,8	19,8	20,6	20,6	20,6	30,5	30,5	30,5
Casemix plus NANDA zorgplan	2827	cart	10,0	10,1	10,2	14,2	15,2	15,9	20,7	20,9	21,3	19,3	27,5	32,4



## Resultaten modellen zoals in figuur 27

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	2827	random forest	24,7	24,7	24,7	27,1	27,1	27,1	46,3	46,3	46,3	37,5	37,5	37,5
Casemix	2827	cart	25,4	25,6	25,8	23,8	24,5	25,1	46,9	47,4	47,7	33,8	35,0	36,4
Casemix plus NANDA totaal	2827	random forest	24,6	24,6	24,6	27,5	27,5	27,5	45,3	45,3	45,3	40,1	40,1	40,1
Casemix plus NANDA totaal	2827	cart	25,7	26,0	26,2	22,8	23,5	24,3	47,0	47,5	47,7	32,9	34,6	36,0
Casemix plus NANDA zorgplan	2827	random forest	24,4	24,4	24,4	28,1	28,1	28,1	45,7	45,7	45,7	39,4	39,4	39,4
Casemix plus NANDA zorgplan	2827	cart	25,7	25,9	26,1	23,0	23,6	24,0	47,2	47,6	47,9	33,5	34,5	35,6

## Resultaten modellen zoals in figuur 28

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	1961	random forest	8,8	8,8	8,8	11,8	11,8	11,8	16,1	16,1	16,1	13,7	13,7	13,7
Casemix	1961	cart	9,0	9,1	9,2	7,0	8,1	8,9	16,4	16,9	17,4	3,3	5,7	7,8
Casemix plus Omaha totaal	1961	random forest	8,3	8,3	8,3	16,3	16,3	16,3	15,6	15,6	15,6	20,7	20,7	20,7
Casemix plus Omaha totaal	1961	cart	8,9	8,9	9,1	8,5	9,9	10,8	16,3	16,7	17,1	4,4	7,7	11,1
Casemix plus Omaha zorgplan	1961	random forest	8,4	8,4	8,4	15,8	15,8	15,8	15,6	15,6	15,6	20,1	20,1	20,1
Casemix plus Omaha zorgplan	1961	cart	8,7	8,8	8,9	10,0	11,1	12,2	16,1	16,5	17,0	7,5	10,2	12,3

## Resultaten modellen zoals in figuur 29

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	1961	random forest	30,3	30,3	30,3	19,7	19,7	19,7	55,8	55,8	55,8	28,2	28,2	28,2
Casemix	1961	cart	31,4	31,7	31,8	15,1	15,7	16,2	57,8	58,4	58,7	19,1	20,5	22,9
Casemix plus Omaha totaal	1961	random forest	31,1	31,1	31,1	17,9	17,9	17,9	56,6	56,6	56,6	26,1	26,1	26,1
Casemix plus Omaha totaal	1961	cart	31,9	32,1	32,5	13,8	14,5	15,0	58,4	58,9	59,8	16,3	19,1	21,0
Casemix plus Omaha zorgplan	1961	random forest	30,4	30,4	30,4	19,7	19,7	19,7	55,9	55,9	55,9	27,9	27,9	27,9
Casemix plus Omaha zorgplan	1961	cart	31,8	32,0	32,1	14,4	14,8	15,3	58,3	58,8	59,2	18,0	19,4	21,5

## Resultaten modellen zoals in figuur 30 en figuur 31

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	4999	random forest	9,3	9,3	9,3	15,0	15,0	15,0	19,2	19,2	19,2	25,5	25,5	25,5
Casemix	4999	cart	9,5	9,5	9,6	12,1	12,6	13,2	19,4	19,6	19,9	17,5	20,9	24,1
Casemix met geschaalde uren	4999	random forest	9,2	9,2	9,2	13,9	13,9	13,9	18,7	18,7	18,7	24,3	24,3	24,3
Casemix met geschaalde uren	4999	cart	9,4	9,5	9,5	11,3	11,7	12,3	18,9	19,1	19,2	16,8	20,4	22,3
Casemix & aanbieder ID	4999	random forest	9,2	9,2	9,2	15,9	15,9	15,9	19,1	19,1	19,1	26,2	26,2	26,2
Casemix & aanbieder ID	4999	cart	9,4	9,5	9,6	12,5	13,0	13,6	19,4	19,8	20,0	16,5	20,1	22,2

Resultaten modellen zoals in figuur 32

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	4999	random forest	9,3	9,3	9,3	15,0	15,0	15,0	19,2	19,2	19,2	25,5	25,5	25,5
Casemix	4999	cart	9,5	9,5	9,6	12,1	12,6	13,2	19,4	19,6	19,9	17,5	20,9	24,1
Casemix plus maaltijd vraag	4999	random forest	9,3	9,3	9,3	15,1	15,1	15,1	19,2	19,2	19,2	25,2	25,2	25,2
Casemix plus maaltijd vraag	4999	cart	9,5	9,5	9,6	12,1	12,6	13,2	19,4	19,6	19,9	17,5	20,9	24,1

Resultaten modellen zoals in figuur 33

Label voorspellers	N	Methode	min	MAPE	max	min	CPM	max	min	RMSE	max	min	R2	max
Casemix	4999	random forest	26,8	26,8	26,8	24,4	24,4	24,4	50,7	50,7	50,7	33,4	33,4	33,4
Casemix	4999	cart	27,6	27,7	27,8	21,6	21,8	22,1	51,4	51,6	51,8	29,8	30,6	31,2
Casemix plus maaltijd vraag	4999	random forest	25,9	25,9	25,9	26,9	26,9	26,9	49,6	49,6	49,6	36,2	36,2	36,2
Casemix plus maaltijd vraag	4999	cart	26,9	27,1	27,2	22,9	23,6	24,1	50,6	51,1	51,6	30,1	32,0	33,5

## B2. Effect toevoegen NANDA- en Omaha-kenmerken


In de rapportage ligt de focus op kenmerken die voor alle vier de zorgaanbieders beschikbaar zijn. Hier is voor gekozen omdat het toevoegen van NANDA- of Omaha-kenmerken weinig doet voor de voorspelkracht, en bovendien niet worden geselecteerd in de beslisbomen.

Hier presenteren we de voorspelkracht van de modellen inclusief NANDA- en Omaha-kenmerken. Deze modellen gaan telkens over twee zorgaanbieders, aangezien twee van de vier zorgaanbieders uit de pilot met Omaha werken en twee zorgaanbieders met NANDA.

### Resultaten NANDA modellen


We zien in figuur 26 dat de voorspelkracht van de case-mix vragenlijst voor formele zorginzet bij de aanbieders die werken met NANDA op ca. 28% ligt (voor CART). Het toevoegen van NANDA-kenmerken verbetert de voorspelkracht niet.

Figuur 26: Resultaten inclusief NANDA kenmerken (formele uren)



Voor de uitkomstmaat formele + informele uren verbetert CART ook niet na toevoegen van de NANDA-kenmerken (figuur 27). De random forest laat hierbij wel een kleine verbetering zien, van 37% naar tegen de 40%.

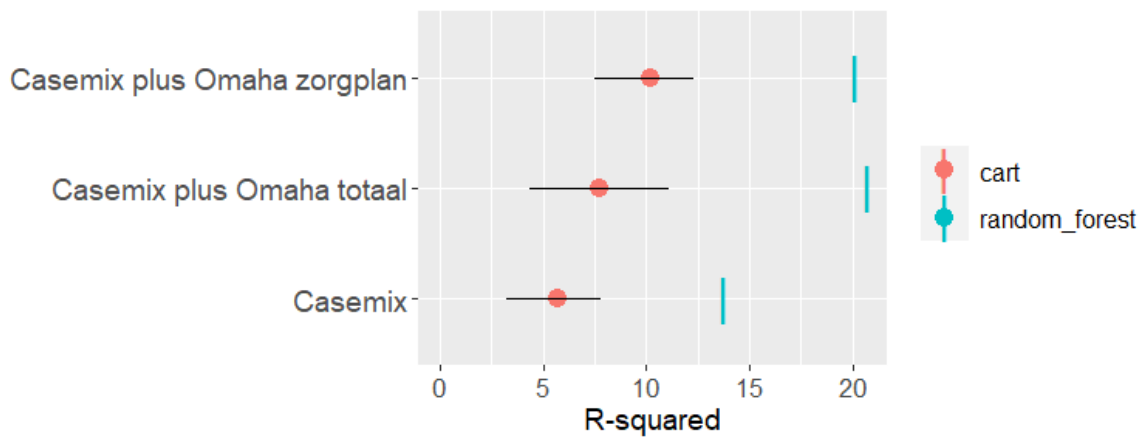
**Figuur 27: Resultaten inclusief NANDA kenmerken (formeel en informeel uren)**




**Resultaten Omaha modellen**

Wat opvalt is dat de case-mix vragenlijst in termen van R-kwadraat een lagere voorspelkracht heeft bij de aanbieders die werken met Omaha dan bij de aanbieders die werken met NANDA. Omaha voegt voorspelkracht toe. Figuur 28 toont dit voor de formele uren en figuur 29 voor de formele plus informele uren. Voor de CPM zien we minder grote verschillen (zoals te zien in paragraaf B1).

**Figuur 28: Resultaten inclusief Omaha kenmerken (formeel uren)**



**Figuur 29: Resultaten inclusief Omaha kenmerken (formeel en informeel uren)**




### B3 Effect corrigeren urenverschillen tussen zorgaanbieders

De dataset in deze studie is een zogeheten multi-level dataset: cliënten zijn geclusterd binnen de zorgaanbieders omdat ze bij één van de zorgaanbieders in zorg zijn. Als we hier geen rekening mee houden lopen we het risico dat bepaalde patronen gemaskeerd worden door potentiële structurele verschillen in zorginzet tussen zorgaanbieders. We hebben op twee manieren gecontroleerd in hoeverre dit hier speelt. Eerst door de uren van elke zorgaanbieder te schalen met het gemiddelde van alle zorgaanbieders en vervolgens deze geschaalde uren als uitkomstvariabelen mee te nemen. Als tweede methode hebben we het 'ID' van elke zorgaanbieder meegenomen als voorspeller in de modellen.


Figuur 30 laat het effect zien van het schalen van de uren. We vergelijken het model met en zonder geschaalde uren. Zowel bij gebruik van CART als bij random forest is er nauwelijks verschil in voorspelkracht.

**Figuur 30: Resultaten niet-schalen vs. schalen (formele uren)**



Figuur 31 laat het effect zien van het toevoegen van het zorgaanbieder kenmerk. We vergelijken het model met en zonder zorgaanbieder kenmerk.

**Figuur 31: Resultaten met en zonder zorgaanbieder ID (formele uren)**




We zien dat het schalen van de uren of toevoegen van het zorgaanbieder kenmerken vrijwel niets doet voor de voorspelkracht. Hoewel er wel verschillen zijn tussen de zorgaanbieders, blijken die niet op te wegen tegen de verschillen tussen de cliënten.


## B4. Effect meenemen maaltijd-vraag

De maaltijd vraag uit de case-mix vragenlijst is niet meegenomen in de modellen in de rapportage. Onderstaande figuren laten zien wat het wel behouden van deze vraag voor effect heeft op de voorspelkracht. We vergelijken het model in- en exclusief de maaltijd vraag. We zien dat de maaltijd vraag voor CART nog wat extra voorspelkracht brengt voor het model met formele en informele uren. Voor het formele model zien we geen verbetering.

**Figuur 32: Resultaten met en zonder maaltijd vraag (formele uren)**



**Figuur 33: Resultaten met en zonder maaltijd vraag (formele en informele uren)**



## B5. CV-waarden cliëntprofielen formele zorgvraag

Onderstaande tabel geeft de CV-waarden weer voor de 10 cliëntprofielen die volgen uit de beslisboom voor formele zorgvraag.

Cluster	Aantal cliënten in cluster	Gemiddeld aantal formele uren zorg	CV-waarde
Cluster 1	1930	8	1,06
Cluster 2	959	12	0,89
Cluster 3	862	13	0,97
Cluster 4	77	15	0,82
Cluster 5	36	34	1,50
Cluster 6	697	19	0,87
Cluster 7	254	25	0,91
Cluster 8	62	41	0,95
Cluster 9	61	54	1,31
Cluster 10	61	102	1,05

# Bijlage C: Case-mix vragenlijst

**Pilot "Case-mix in de wijkverpleging"**

**Mei 2019**

Instructies voor het invullen van de vragenlijst

De vragenlijst bestaat uit **11 vragen over de cliënt**; elke vraag heeft meerdere antwoordopties. Wij verzoeken u om deze vragen te beantwoorden **na afloop van uw indicatiestelling**. Alle vragen dienen te worden ingevuld. Het invullen kost maximaal 4-6 minuten van uw tijd. Bij het invullen van de vragenlijst vragen wij u om:

- Uw beoordeling te baseren op de actuele status van de cliënt (over de afgelopen 3-5 dagen); dus niet op de mogelijkheden van de cliënt. Dit betekent dat een persoon die weigert om zich bijvoorbeeld te wassen (vraag 8), niet wordt beschouwd als "zelfstandig" qua wassen, ook al vermoedt u dat hij er wel toe in staat is. Onder zelfstandig verstaan we "het uitvoeren van de activiteit zonder toezicht of aansporing, **en zonder fysieke ondersteuning**".
- Bij vragen over het functioneren van de cliënt (vraag 2 t/m 10) geen rekening te houden met de mantelzorg of formele zorg die een cliënt al krijgt: we willen met deze vragenlijst in kaart brengen in hoeverre de cliënt zelf in staat is deze activiteiten uit te voeren, onafhankelijk van ondersteuning door derden (zoals de mantelzorger, wijkverpleegkundige, wijkteam of diensten als Tafeltje Dekje).
- Bij elke vraag één antwoordoptie te kiezen (tenzij anders is aangegeven in de vraag), die het beste weergeeft wat de actuele status van de cliënt is.

Hartelijk bedankt voor uw medewerking!

Het onderzoeksteam van de pilot,

Anne van den Bulck, Arianne Elissen, Dirk Ruwaard; Universiteit Maastricht  
Maud de Korte, Jaap Stam, Gertjan Verhoeven, Thijs Vietje, Misja Mikkers; NZa

*Onderdeel van het "Wetenschappelijk Programma Wijkverpleging" in opdracht van de Nederlandse Zorgautoriteit*



## Vragenlijst case-mix in de wijkverpleging\*

a. Cliëntnummer: .....

b. Wie is de voornaamste mantelzorgverlener van de cliënt? (1 antwoord omcirkelen) (LET OP: Het gaat hier om onbetaalde zorg door (een) naaste(n) van de cliënt)

Echtgenoot/partner	Dochter/zoon	Broer/zus/ander familie lid	Vriend(in)/kennis	Er is geen mantelzorgverlener	Anders, namelijk:
--------------------	--------------	--------------------------------	-------------------	-------------------------------	-------------------

c. Hoeveel uur mantelzorg heeft de cliënt naar schatting in de afgelopen week ontvangen? (LET OP: Het gaat hier om onbetaalde zorg door (een) naaste(n) van de cliënt. Mantelzorg definiëren we als "zorg die mensen vrijwillig en onbetaald verlenen aan een naaste met fysieke, verstandelijke of psychische beperkingen. Het gaat om zorg die meer is dan in een persoonlijke relatie gebruikelijk is: hiervan is sprake indien het taken betreft die de zorgvrager bij normale gezondheid zelf had gedaan (bijv. huishoudelijke taken, persoonlijke verzorging) of bij normale gezondheid niet nodig waren geweest (bijv. fysieke begeleiding, regievoering, verpleging)".) ..... uur

<b>1</b>	<b>Verwachte verloop (in de komende maand)</b>	De toestand en/of zelfstandigheid van de cliënt zal naar verwachting verbeteren.  <input type="checkbox"/>	De toestand en/of zelfstandigheid van de cliënt blijft naar verwachting stabiel.  <input type="checkbox"/>	De toestand en/of zelfstandigheid van de cliënt blijft naar verwachting instabiel (met ups en downs).  <input type="checkbox"/>	De toestand en/of zelfstandigheid van de cliënt zal naar verwachting verslechteren.  <input type="checkbox"/>	De cliënt ontvangt palliatief terminale zorg en heeft een levensverwachting van minder dan 3 maanden.  <input type="checkbox"/>
<b>2</b>	<b>Maaltijd bereiden</b>  LET OP: Boodschappen doen valt hier niet onder.	De cliënt is zelfstandig in het bereiden van alle maaltijden.  <input type="checkbox"/>	De cliënt heeft gedeeltelijke hulp van derden nodig (bijv. aansporing, toezicht of fysieke ondersteuning) bij het bereiden van (een) maaltijd(en).  <input type="checkbox"/>	Het bereiden van alle maaltijden moet volledig worden overgenomen door derden.  <input type="checkbox"/>		





7	<b>Kleden</b>	De cliënt kan zich zelfstandig aan- en uitkleden. <input type="checkbox"/>	De cliënt heeft gedeeltelijke hulp van derden nodig (bijv. aansporing, toezicht of fysieke ondersteuning) om zich aan- en/of uit te kleden. <input type="checkbox"/>	De cliënt moet volledig geholpen worden door derden om zich aan- en uit te kleden. <input type="checkbox"/>		
8	<b>Wassen/douchen</b>	De cliënt wast/doucht zich zelfstandig. <input type="checkbox"/>	De cliënt heeft gedeeltelijke hulp van derden nodig (bijv. aansporing, toezicht of fysieke ondersteuning) om zich te wassen/douchen. <input type="checkbox"/>	De cliënt moet volledig geholpen worden door derden om zich te wassen/douchen. <input type="checkbox"/>		
9	<b>Medicatiegebruik</b>	De cliënt neemt zelfstandig medicatie. <input type="checkbox"/>	De cliënt heeft gedeeltelijke hulp van derden nodig (bijv. medicatie klaarzetten, aansporing of toezicht) bij het nemen van medicatie. <input type="checkbox"/>	Het toedienen van medicatie moet volledig worden overgenomen door derden. <input type="checkbox"/>	De cliënt heeft geen medicatie. <input type="checkbox"/>	
10	<b>Cognitieve vaardigheden voor de dagelijkse besluitvorming</b>  LET OP: Onder "dagelijkse besluitvorming" verstaan we het maken van beslissingen over taken van het dagelijks leven (bijv. wanneer op te staan, eten, welke kleren dragen, wat te gaan doen)	De cliënt heeft geen cognitieve beperking: hij/zij kan volledig zelfstandig adequate beslissingen nemen. <input type="checkbox"/>	De cliënt heeft vanwege (een verdenking op) een cognitieve beperking gedeeltelijke hulp van derden nodig (bijv. aansporing of toezicht) om adequate beslissingen te nemen. <input type="checkbox"/>	De cliënt kan vanwege een cognitieve beperking zelf geen adequate beslissingen nemen: de besluitvorming moet volledig worden overgenomen door derden. <input type="checkbox"/>		



# Bijlage D: Factsheet case-mix vragenlijst



*In opdracht van het Ministerie van Volksgezondheid, Welzijn en Sport ontwikkelt de Nederlandse Zorgautoriteit (NZa) een nieuw bekostigingsmodel voor de wijkverpleging. Er wordt onderzocht of bekostiging van wijkverpleging mogelijk is gebaseerd op groepen cliënten met vergelijkbare kenmerken. De zorg wordt dan niet per uur per cliënt betaald, maar per periode per type cliënt, ook wel case-mix genoemd.*

*Om dit te ontwikkelen wordt aan de hand van cliëntkenmerken gekeken wat belangrijke voorspellers zijn van zorggebruik in de wijk. Verpleegkundige registratiesystemen, zoals NANDA en Omaha, worden hiervoor als basis gebruikt. In deze systemen worden potentieel belangrijke voorspellende cliëntkenmerken echter niet of niet eenduidig vastgelegd. Daarom is door de Universiteit Maastricht een 'Case-mix vragenlijst' ontwikkeld. Deze factsheet beschrijft hoe deze vragenlijst eruit ziet, hoe deze is ontwikkeld en waar deze voor wordt gebruikt.*

## Wat is de 'Case-mix vragenlijst'?

De 'Case-mix vragenlijst' bevraagt middels 11 items het functioneren van de cliënt. Het doel van deze vragenlijst is om, als aanvulling op de verpleegkundige registratiesystemen, op een gestandaardiseerde manier gegevens te verzamelen over potentieel voorspellende cliëntkenmerken van zorggebruik te verzamelen. De vragen hebben betrekking op potentieel belangrijke voorspellende cliëntkenmerken in een aantal domeinen:

- Het verwachte verloop (item 1);
- Functionele zelfredzaamheid (item 2 t/m 9);
- Cognitief functioneren (item 10);
- Sociale steun (item 11).

In de periode van juni tot en met december 2019 hebben wijkverpleegkundigen van 4 zorgaanbieders de 'Case-mix vragenlijst' ingevuld na afloop van een indicatiestelling of herindicatiestelling. Op dit moment worden verzamelde data, samen met data uit de verpleegkundige registratiesystemen en registratiedata van zorgverzekeraars, geanalyseerd door de NZa voor de ontwikkeling van een case-mix model. Daarnaast test de Universiteit Maastricht hoe eenduidig de antwoorden zijn die door wijkverpleegkundigen zijn gegeven op de vragen. Op basis hiervan kan de case-mix vragenlijst nog worden doorontwikkeld.

## De 11 items van de case-mix vragenlijst


1. Verwachte verloop
2. Maaltijd bereiden
3. Voeden
4. Continentie
5. Toiletbezoek
6. Mobiliteit
7. Kleden
8. Wassen/douchen
9. Medicatiegebruik
10. Cognitieve vaardigheden voor de dagelijkse besluitvorming
11. Mantelzorg

## Waar is de 'Case-mix vragenlijst' op gebaseerd?

De vragen van een eerste concept vragenlijst zijn door onderzoekers zo veel mogelijk geformuleerd op basis van bestaande gevalideerde vragenlijsten. Voor het domein 'Verwachte verloop' is een gevalideerde schaal gebruikt als basis, namelijk de Palliative Care Phase tool (Masso et al., 2015). Voor het domein 'Fysiek functioneren' zijn twee gevalideerde en breed geaccepteerde vragenlijsten gebruikt: de Katz-schaal voor ADL (Hartigan, 2007) en delen van de Lawton en Brody schaal voor IADL (Lawton & Brody, 1969). Voor het domein 'Cognitief functioneren' is een vraag uit de InterRAI gebruikt (Morris et al., 1997). Voor het domein 'Sociale steun' is door de onderzoekers zelf een vraag geformuleerd, rekening houdend met de terminologie over mantelzorggebruik van het Sociaal en Cultureel Planbureau en een vraag uit een bestaand case-mix model uit Nieuw-Zeeland.

## Hoe is de 'Case-mix vragenlijst' tot stand gekomen?

Om voorspellers van zorggebruik te identificeren zijn tussen 2017 en 2019 drie studies uitgevoerd:



De geïdentificeerde potentieel voorspellende cliëntkenmerken, die naar verwachting niet of niet eenduidig worden vastgelegd in verpleegkundige registratiesystemen, zijn opgenomen in een eerste concept versie van de 'Case mix vragenlijst'.



Vervolgens hebben er 4 bijeenkomsten plaatsgevonden, bij 4 zorgaanbieders. Groepen van minimaal 3 wijkverpleegkundigen hebben aan de hand van een casusbeschrijving de vragenlijst ingevuld. Alle opmerkingen en onduidelijkheden zijn verzameld. Aan de hand daarvan is de vragenlijst op een aantal punten aangepast. Zo is de volgorde van de items aangepast (bijvoorbeeld 'Continentie' en 'Toiletbezoek' bij elkaar plaatsen) en is het item 'Verwacht verloop' toegevoegd inclusief de antwoordoptie 'Cliënt ontvangt palliatief terminale zorg'. Wijkverpleegkundigen gaven namelijk aan dat de palliatieve fase niet direct uit NANDA of Omaha te halen is en dat ze 'de mogelijkheid tot verbetering op termijn' nergens kwijt kunnen. Tot slot is het merendeel van de antwoordopties versimpeld en zijn er antwoordopties samengevoegd.



Daarna is de vragenlijst bij 22 cliënten door wijkverpleegkundigen kleinschalig getest in de praktijk. De opmerkingen die hieruit volgden zijn vervolgens in de vragenlijst verwerkt. Dit heeft geleid tot de formulering van de definitieve vragenlijst.

### Meer lezen over deze en voorgaande onderzoeken?

- NZa. *Voortgangsrapportage Doorontwikkeling bekostiging wijkverpleging (rapport)*. Februari 2019. URL [https://puc.overheid.nl/nza/doc/PUC\\_268372\\_22/1/](https://puc.overheid.nl/nza/doc/PUC_268372_22/1/)
- Van den Bulck, A.O.E., Metzelthin, S.F., Elissen, A.M.J., Stadlander, M.C., Stam, J.E., Wallinga, G. & Ruwaard, D. *Which client characteristics predict home care needs? Results of a survey study among Dutch home care nurses*. 2018. *Health and Social Care in the Community*, (27)93-104. <https://doi.org/10.1111/hsc.12611>
- Van den Bulck, A.O.E., De Korte, M.H., Elissen, A.M.J., Metzelthin, S.F., Mikkers, M.C., & Ruwaard, D. *A systematic review of case-mix models for home health care payment: Making sense of variation*. 2020. *Health Policy*. <https://doi.org/10.1016/j.healthpol.2019.12.012>
- De Korte, M.H., Verhoeven, G.S., Elissen, A.M.J., Metzelthin, S.F., Ruwaard, D. & Mikkers, M.C. *Using machine learning to assess the predictive potential of standardized nursing data for home care case-mix classification*. (submitted for publication)

#### Contact

Anne van den Bulck, RN MSc

Promovenda Universiteit Maastricht

[a.vandenbulck@maastrichtuniversity.nl](mailto:a.vandenbulck@maastrichtuniversity.nl)

Anne Elissen, PhD

Assistent Professor Universiteit Maastricht

[a.elissen@maastrichtuniversity.nl](mailto:a.elissen@maastrichtuniversity.nl)



Nederlandse  
Zorgautoriteit