

Voorspellen van patiëntaankomsten en klinische opnames in de acute zorg met behulp van Machine Learning technieken.

ARIEF IBRAHIM, 18 juli 2019

Faculteit van Electrotechniek, Wiskunde en Informatica, Universiteit Twente

Begeleiders

Dr.ir. M. Van Keulen (Maurice)

Dr. C.G.M. Groothuis-Oudshoorn (Karin)

M.A. Bruens MSc. (Manon)

Samenvatting

Één van de uitdagingen van acute zorgorganisaties, zoals Spoedeisende Hulpafdelingen (SEH) of Huisartsenposten (HAP), is de toenemende trend naar zorgvragen. Het onvermogen om voldoende zorg te verlenen tijdens drukte, kan leiden tot overcrowding. Als gevolg hiervan kan de kwaliteit van zorg dalen, wordt de wachttijd langer en er kunnen financiële verliezen zijn. Uit Nederlands onderzoek blijkt dat bijna 70% van de SEH-managers meerdere keren per week overcrowding ervaart op de SEH. Een ander onderzoek benadrukt ook het belang van het hebben van effectieve oplossingen voor het aanpakken van de toenemende vraag naar acute zorg.

Het meten echter van het moment waarop de acute zorgvraag overgaat in overcrowding is een uitdagend probleem. De belangrijkste oorzaak is dat er geen universele definitie is van overcrowding en hoe dit gemeten kan worden. Met andere woorden, verschillende acute zorgorganisaties hebben andere kenmerken van overcrowding. Daarom wordt in dit afstudeerverslag het dagelijkse aantal patiënten gebruikt als een indirecte indicator van overcrowding. De mogelijkheid om het aantal patiënten voor de volgende dag nauwkeurig te voorspellen, kan waardevolle informatie opleveren voor het management van acute zorgorganisaties om in te spelen op eventuele overcrowding. Vanuit verschillende voorspelmethodeken is in dit onderzoek voorspellen met behulp van machine learning (ML) gebruikt en wel om drie redenen: (1) de effectiviteit van ML-methoden die als een black box kunnen worden beschouwd, (2) het vermogen van ML om de correlatie en de belangrijkheid van externe factoren (bijv. temperatuur en vochtigheid) weer te geven, en (3) het vermogen van ML om de toekomst te voorspellen met een bepaald niveau van nauwkeurigheid, foutenmarge en betrouwbaarheidsinterval.

De historische data van de SEH en HAP in Winterswijk te Nederland, zijn gebruikt om twee voorspelmodellen te onderzoeken en ontwikkelen, waaraan ook externe data van het weer en pollen zijn toegevoegd. Ook zijn de stakeholders geïnteresseerd in het voorspellen van de kans op opname in het ziekenhuis na SEH bezoek door middel van ML-technieken. Naast deze twee punten is ook onderzocht wat de lineaire correlatie tussen externe factoren en enkele specifieke patiëntengroepen (bijv. leeftijd of diagnose) is. Op basis van deze doelstellingen, is de belangrijkste onderzoeksvraag van dit afstudeerverslag geformuleerd als:

"In hoeverre kan men in acute zorgorganisaties zoals de SEH en HAP, gebruikmaken van machine learning-technieken?"

De methodologie die wordt gebruikt in dit onderzoek is gebaseerd op het Cross-Industry Standard Proces voor Data Mining (CRISP-DM), in het bijzonder de eerste vijf fasen, namelijk *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling* en *Evaluation*. Deze vijf fasen kunnen worden opgesplitst in meer gedetailleerde activiteiten. In de *Business Understanding*-fase worden drie activiteiten uitgevoerd, namelijk (a) probleemidentificatie, (b) motivatie, doelstelling en reikwijdte, en (c) domeinanalyse. In de *Data Understanding*-fase worden ook drie activiteiten uitgevoerd, namelijk (a) statistische samenvatting en visualisatie, (b) tijdsreeksanalyse en (c) functieanalyse. In de fase *Data Preparation* worden vier hoofdactiviteiten uitgevoerd, namelijk (a) Aggregatie, (b) Integratie, (c) Feature Engineering, (d) Segregatie. In de *Modellings*-fase worden vier activiteiten uitgevoerd, namelijk (a) modelbouw, (b) bias versus variantieanalyse, (c) functieselectie, (d) modeloptimalisatie. In de *Evaluatie*-fase zijn twee activiteiten uitgevoerd, namelijk (a) modelvergelijking, en (b) resultaat in analyse. Naast deze methode, werd literatuuronderzoek gedaan om een hybride ML-model te identificeren met behulp van SARIMAX en Gradient Tree Boosting.

De voornaamste resultaten uit dit onderzoek zijn (Tabel 1):

- Ten eerste kwam het voorspellen van de SEH vraag met een hybride model, SARIMAX (0,0,0) x (1,0,1,7) en Gradient Tree Boosting, als beste model met een mean absolute percentage error (MAPE) van 16,50%, een root-mean-square error (RMSE) van 6,56 en een mean absolute error (MAE) van 5,25. Om dit resultaat te bereiken, waren slechts zes variabelen, namelijk “doordeweekse dag”, “HAP open”, “maximum temperatuur van gisteren (-1d)”, “aantal patiënten met ICPCode L gisteren (-1d) op de HAP”, “was het twee dagen geleden (-2d) een doordeweekse dag”, “was het drie dagen geleden (-3d) een doordeweekse dag”, vereist uit de 1.132 beschikbare variabelen.
- Ten tweede, kwam SARIMAX (1, 0, 1) x (0, 0, 0, 7) en Gradient Boosting, ook naar voren als het beste model voor het voorspellen van de vraag op de HAP met een hybride model, met een MAPE van 13,70%, een RMSE van 13,94, en een MAE van 9.43. Om deze resultaten te bereiken waren zeven variabelen, namelijk “doordeweekse dag”, “HAP open”, “aantal patiënten met urgentiecode U5 een week geleden (-7d)”, “was het gisteren (-1d) een feestdag”, “was het gisteren (-1d) een doordeweekse dag”, “was het drie dagen geleden (-3d) een doordeweekse dag”, “was het vijf dagen geleden (-5d) een doordeweekse dag”, vereist uit de 1.132 beschikbare variabelen.
- Ten derde leverde het voorspellen van de klinische opname van SEH patiënten met Gradient Boosting Classifier de beste resultaten met een nauwkeurigheid van 78%, een precisie van 73%, een sensitiviteit van 73%, een F1 score van 73%, en een ROC-AUC van 77%. Om deze resultaten te bereiken waren 21 variabelen nodig uit de 38 beschikbare variabelen. De top drie uit deze 21 variabelen zijn: “hoofdbehandelaar is chirurgie”, “leeftijd” en “urgentiecategorie groen”.

Tabel 1: Samenvatting resultaten

Doel	Beste ML-model	Resultaat op de testing data set	Belangrijke variabelen
Voorspellen aantal SEH patiënten	Hybrid model (SARIMAX and Gradient Tree Boosting)	MAPE: 16.50% RMSE: 6.56 MAE: 5.25	Doordeweekse dag HAP open Maximum temperatuur - 1d ICPCcode L – 1d Doordeweekse dag – 2d Doordeweekse dag – 3d
Voorspellen aantal HAP patiënten	Hybrid model (SARIMAX and Gradient Tree Boosting)	MAPE: 13.70% RMSE: 13.94 MAE: 9.43	Doordeweekse dag HAP open Urgentie U5 – 7d Feestdag – 1d Doordeweekse dag – 1d Doordeweekse dag – 3d Doordeweekse – 5d
Voorspellen klinische opname na SEH	Gradient Boosting Classifier	Nauwkeurigheid: 78% Precisie: 73% Sensitiviteit: 73% F1 score: 73% ROC-AUC: 77%	Hoofdbehandelaar chirurgie Leeftijd Urgentiecategorie groen

Om de belangrijkste onderzoeksvraag te beantwoorden zijn verschillende machine learning-technieken toegepast op twee gebieden in het domein van de acute zorg, namelijk (1) Instroom, door het voorspellen van het aantal patiënten en (2) Uitstroom, door het voorspellen van de klinische opname. Bij de instroom was het resultaat van dit onderzoek dat het overfitting-probleem bij een enkele SARIMAX werd opgelost door de feature-selectietechniek toe te passen met Lasso. Het hybride model kwam echter naar voren als het beste ML-prognosemodel voor de SEH en HAP. Bij de uitstroom was het resultaat van dit onderzoek dat Gradient Boosting Classifier de beste voorspelling opleverde, vooral in de sensitiviteit-score. De optimalisatie door middel van hyperparametrische technieken was in staat om de uitstroomvoorspelling te verbeteren. Verdere verbetering is mogelijk via ROC en Precision-Recall curve-analyse.

Het volledige afstudeerverslag is hier te vinden: <https://purl.utwente.nl/essays/79016>