

Waterstandsverwachtingen met behulp van Machine Learning

Casus Bovenmark West-Brabant

DORIEN HONINGH, JELLE DE JONG, BRAM BLOKS, HERMAN MONDEEL & KLAAS-JAN DOUBEN

De snelle ontwikkelingen op het gebied van Machine Learning (ML) hebben ervoor gezorgd dat deze data-analysemethode voor steeds meer doeleinden gebruikt wordt en vaak een kostenefficiënt alternatief vormt voor bestaande methodes. Deze studie onderzoekt de meerwaarde van Machine Learning in het operationele waterbeheer. Hiervoor zijn testen uitgevoerd om waterstandreeksen te genereren voor de Bovenmark ten zuiden van Breda, in het beheergebied van Waterschap Brabantse Delta. In het onderzoek zijn vier verschillende Machine Learning algoritmes getest: Autoregressive Integrated Moving Average (ARIMA), Gradient Boosting Regression Trees (GBRT), Long Short-Term Memory (LSTM) en Multi-Layer Perceptron (MLP). De meest nauwkeurige verwachtingen zijn behaald door waterstandsveranderingen te berekenen en deze te transformeren naar momentane waterstanden. Dit bleek beter te werken dan direct de waterstanden te berekenen. De nauwkeurigheid van de berekeningen neemt af als men meerdere dagen vooruit wil voorspellen. De beste resultaten werden behaald met GBRT, welke voor een verwachting van één dag vooruit een gemiddelde verklaarde variantie (R^2) van 0,95 had en voor drie dagen vooruit een gemiddelde R^2 van 0,80, met een gemiddelde absolute afwijking van 0,006 m.

Artikel

Inleiding

Een van de hoofdtaken van Waterschap Brabantse Delta is het beheer en reguleren van waterstanden binnen haar beheergebied. Het waterschap gebruikt voor het hoofdwatersysteem een simulatiemodel (SOBEK) om afvoeren en waterstanden een aantal dagen vooruit te kunnen voorspellen en zo te kunnen anticiperen op hoogwatergebeurtenissen.

Met Machine Learning is het tegenwoordig mogelijk om trends en verbanden te ontdekken zonder expliciet geprogrammeerd te zijn, wat wel het geval is voor deterministische modellen (zoals SOBEK). Het Machine Learning algoritme zoekt naar verbanden en trends in een historische dataset. Dit wordt "training" van het algoritme genoemd. Vervolgens worden deze verbanden gebruikt om voorspellingen te generen in de testfase.

Het doel van deze studie is te onderzoeken of met deze algoritmes waterstanden voorspeld kunnen worden met voldoende betrouwbaarheid en korte rekentijd. De focus ligt hier op de voorspelling van piekwaterstanden. Het waterschap is met name geïnteresseerd in waterstandsverwachtingen voor 1 dag (benodigdeanticipatie periode) en 3 dagen (weekend) vooruit.

Casus Bovenmark

Het beheergebied van Waterschap Brabantse Delta is weergegeven in Afbeelding 1. Dit onderzoek focust zich op de Bovenmark, een beekstelsysteem gelegen ten zuiden van Breda. Het is een grensoverschrijdend stroomgebied, gelegen in Nederland en België. Het Nederlandse deel is grotendeels gekanaliseerd in de jaren 1960. Vervolgens hebben tot en met 2005 verschillende systeemveranderingen plaatsgevonden, waaronder hermeandering, plaatsing van vispassages en het aanpassen van de waterdiepte. De Bovenmark is 15 tot 20 m breed, circa 3 m diep en wordt gekenmerkt door een regenwaterregime. Het landgebruik is voornamelijk agrarisch.

In dit onderzoek is gefocust op het Nederlandse deel van het stroomgebied, welke groen gemarkeerd is in Afbeelding 1. Het laagste punt in het watersysteem is 2 m+NAP en is gelegen bij Breda. Het hoogste punt ligt op 26 m+NAP nabij Baarle-Nassau op Belgisch grondgebied. Het onderste paneel van Afbeelding 1 geeft de meetlocatie Blauwe Kamer (locatie 1) weer, welke geselecteerd is als testlocatie. Daarnaast staan in dit paneel ook weergegeven de grondwatermeetpunten (locatie 2 en 3), de locatie van KNMI-station Gilze Rijen (locatie 4) en het bovenstroomse meetpunt Hazeldonksebeek-Paandijksestraat (locatie 5). Deze zijn als extra parameters gebruikt voor het verkrijgen van waterstandsverwachtingen.

Materiaal en methode

Machine Learning algoritmes

Er zijn tegenwoordig veel verschillende Machine Learning algoritmes beschikbaar. Voor toepassingen in het waterbeheer is het echter een vereiste dat de algoritmes met tijdreeksen kunnen werken. Drie geschikte categorieën van algoritmes zijn geselecteerd; Autoregressive Integrated Moving Average (ARIMA), Gradient Boosting Regression Trees (GBRT) en Artificial Neural Networks (ANN). Van de laatste categorie zijn twee algoritmes geselecteerd, namelijk Multi-Layer Perceptron (MLP) en Long Short-Term Memory (LSTM). Deze algoritmes worden hieronder kort toegelicht. ARIMA is een statistische methode, die trends en variaties binnen seizoenen kan detecteren in tijdreeksdata. De methode is gebaseerd op het detecteren van ver-



Afbeelding 1 In het bovenste paneel is het beheergebied van Waterschap Brabantse Delta aangegeven en in het onderste paneel zijn de gebruikte meetlocaties weergegeven.


schillen en vertragingen tussen verschillende observaties en de fout ten opzichte van het voortschrijdend gemiddelde (Brownlee, 2017).

GBRT is een algoritme dat voorspellingen genereert door middel van besluitbomen. Deze besluitbomen creëren het algoritme op een zelflerende wijze. Het begint met een willekeurige beslisboom (weak classifier), met als uitkomst een bepaalde waterstand. Vervolgens wordt een nieuwe beslisboom toegevoegd en evalueert het algoritme of deze tot een meer nauwkeurigere voorspelling komt dan de voorgaande. Als dat het geval is wordt die beslisboom aangehouden als nieuwe standaard. Het algoritme voert deze iteratie vele malen uit, totdat het tot een voldoende nauwkeurig beslissend model komt, bestaande uit de verschillende beslissingen die de uiteindelijke besluitboom vormen.

GBRT is meestal opgebouwd uit besluitbomen met vier tot acht niveaus. Na optimalisatie zijn in dit onderzoek zeven niveaus gebruikt. Indien meer niveaus gebruikt worden, gaat het algoritme in het algemeen te veel specifieke relaties leren en neemt de kans op overfitting toe. Overfitting betekent dat het algoritme heel precies kan voorspellen op basis van de data die gebruikt zijn om het model te trainen, maar dat het niet goed in staat is om te voorspellen op basis van andere data voor

bijvoorbeeld een andere periode (Jain, 2016).

Invoer Verborgen laag Uitvoer



Afbeelding 2 Een voorbeeld van hoe de cellen van een MLP-algoritme met elkaar in verbinding staan, om vanuit de invoer data tot model verwachtingen te komen

Een neurale netwerk (ANN) bestaat op hoofdlijnen uit zogenaamde cellen met een activatiefunctie, vergelijkbaar met de werking van onze hersenen. Tussen de cellen zitten verbindingen waar gewichten (waarden) aan hangen (Afbeelding 2), welke via het 'backpropagation algoritme' worden aangepast. Hierdoor is een neurale netwerk in staat veel combinaties te leggen en te onthouden, afhankelijk van de grootte van het netwerk. Hiermee kunnen

zeer nauwkeurige voorspellingen gegenereerd worden. Een nadeel is echter dat het voorspellende model bestaat uit een set van gewichten en functies. Hierdoor is het lastig af te leiden welke parameters precies hebben geleid tot het tot stand komen van de voorspelling, wat maakt dat het een "Black-Box model" is. Over het algemeen worden deze algoritmes gebruikt om een hoge nauwkeurigheid van voorspellingen te behalen, zonder de (complexe) systemen volledig te begrijpen (Colton, 2004).

Python 3.6.3 is gebruikt voor het opstellen van de algoritmes en het verwerken van de data. Hiervoor zijn verschillende modules van de Keras- en Sklearn-bibliotheek gebruikt.

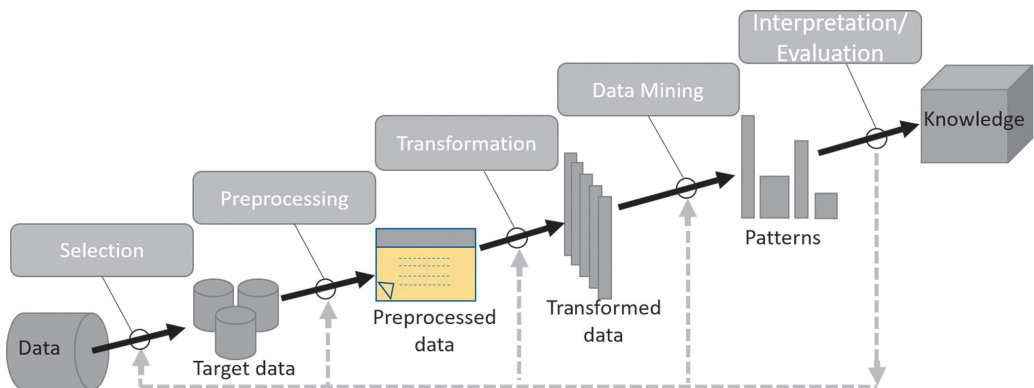
Toegepaste data

Uurlijkse neerslag en temperatuurdata voor de periode 1988-2017 van KNMI-station Gilze Rijen zijn gebruikt. Daarnaast is er gebruik gemaakt van gemiddelde uurlijkse neerslag van het Nederlandse en Belgische deel van het watersysteem voor de periode 2009-2017, verkregen via Hydronet RADAR. Ten slotte zijn de waterstands-

metingen, debietmetingen en uurlijkse grondwaterstandsmetingen (2015-2017) van het waterschap gebruikt.

Methodes

Afbeelding 3 beschrijft de stappen die genomen zijn om uiteindelijk waterstandsvoorspellingen te kunnen genereren. De eerste stap bestond uit het analyseren en selecteren van beschikbare data (selection). Vervolgens werden in de tweede stap de data gecontroleerd op extreme waarden, en zijn opvallende meetresultaten en ontbrekende waarden in de meetreeksen aangepast (preprocessing). De ontbrekende waarden zijn vervolgens opgevuld met lineair geïnterpoleerde waarden. Hierna zijn in stap 3 o.a. neerslagvertragingen in de dataset geïntroduceerd (data transformation), omdat niet alle neerslag direct via de rivier afgevoerd wordt. In stap 4 (data mining) is met behulp van Machine Learning gezocht naar verbanden om vervolgens waterstandsverwachtingen te genereren. Als vuistregel wordt vaak 80% trainingsdata en 20% test data gebruikt (Yufeng, 2017). In deze studie is de lengte van de trainingsdata gevarieerd om de invloed van de trainingslengte op de testresultaten te testen. Voor de doorgerkende scenario's zijn meerdere, maar constante, testperiodes van 75 dagen gebruikt. Ten slotte zijn deze resultaten in stap 5 geanalyseerd en geëvalueerd (interpretation/evaluation), o.a. door de verwachtingen te vergelijken met de monitoringsdata.



Afbeelding 3 Overzicht van het stappenplan om waterstanden te kunnen voorspellen. (Fayyad, Piatestsky-Shapiro, & Smyth, 1996).

Resultaten

De eerste bevindingen voor GBRT- en MLP-algoritmes waren goed, met een correlatie rond de 75%. LSTM voorspelt continue de gemiddelde waterstand met een zeer kleine variatie bij hoge neerslagintensiteiten. ARIMA geeft alleen goede voorspellingen voor 1 tijdstap (1 dag) vooruit, maar heeft een vergelijkbaar probleem als LSTM voor de dynamische voorspelling (bijvoorbeeld 24 tijdstappen vooruit). Vanwege deze eerste bevindingen is gekozen voor een parameteroptimalisatie voor de GBRT- en MLP-algoritmes. Voor deze algoritmes zijn verschillende testen gedaan met variaties in de dataset, de voorspellingsperiode en de voorspelde parameter.

In Tabel 1 staan de resultaten van de meest relevante scenario's; de directe waterstandsvoorspelling, het basisscenario, het basisscenario voor drie dagen vooruit

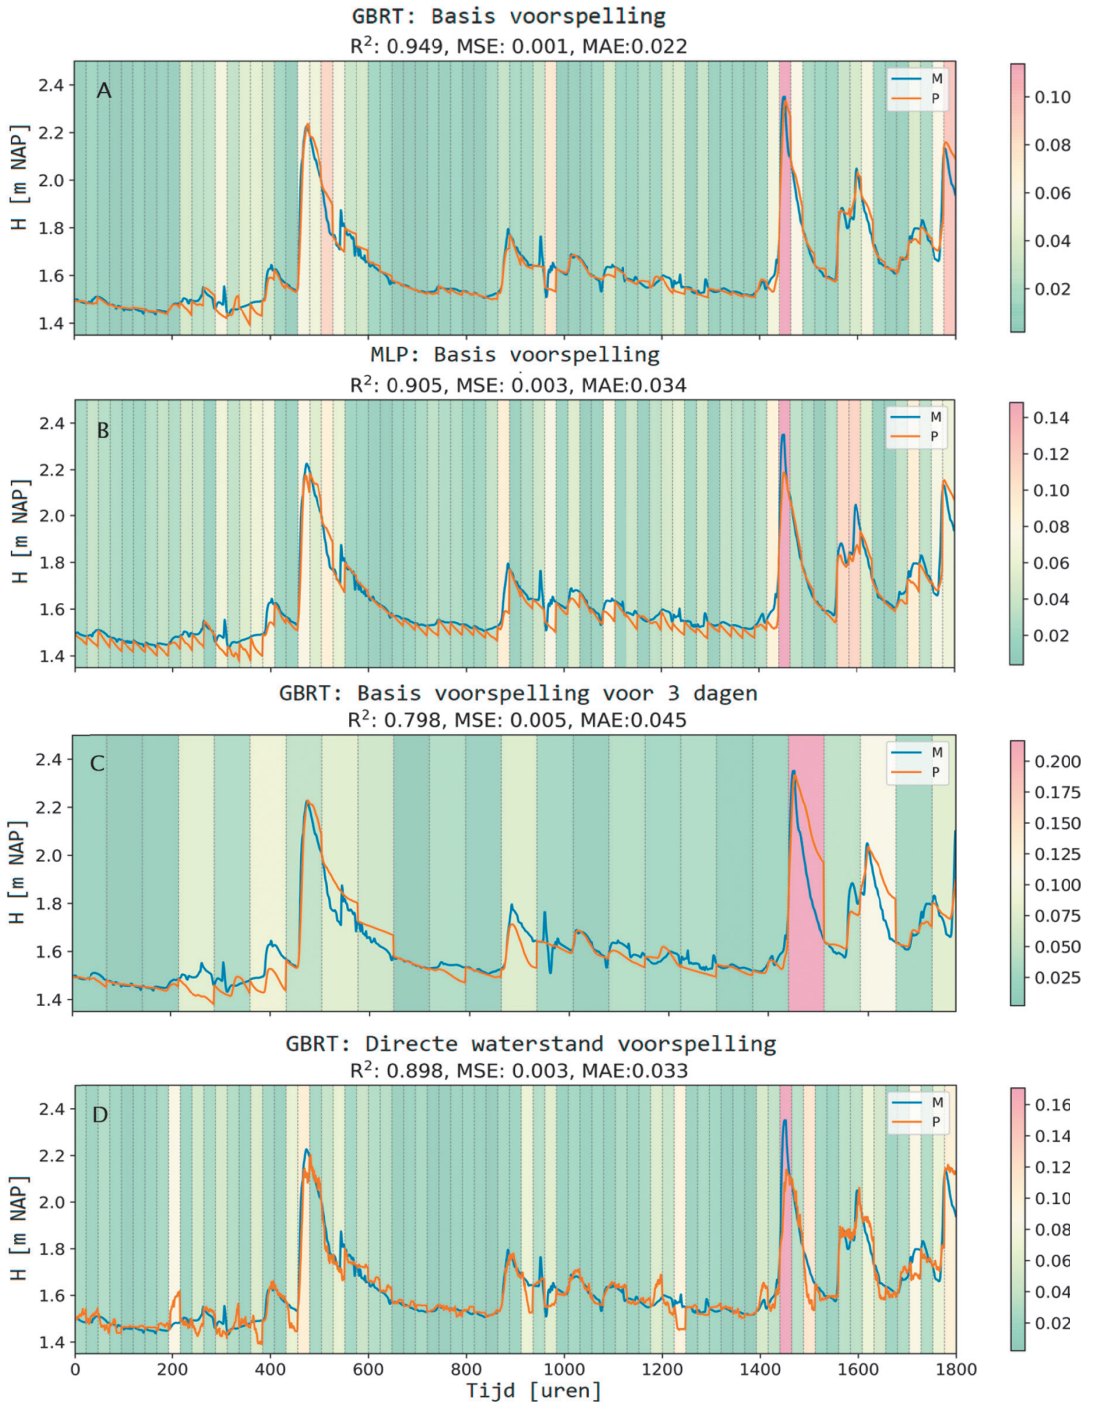
voorspellen, het basisscenario zonder gebiedsneerslag en het basisscenario zonder neerslagvertragingen. Het basisscenario bestaat uit voorspellingen van de waterstandverandering voor 1 dag vooruit. Hiervoor is de neerslag als parameter gebruikt. Het scenario met neerslagvertragingen is gebruikt omdat slechts een deel van de neerslag direct het oppervlaktewater bereikt, terwijl een aanzienlijk deel via het grondwater vertraagd naar het oppervlaktewater afstroomt.

De resultaten van de verschillende scenario's laten zien dat de gemiddelde R^2 waarden hoger liggen voor GBRT dan voor MLP en dus een betere overeenkomst met de monitoringsdata. Eén van de stappen om de betrouwbaarheid van het algoritme te testen is om de trainingsdata meerdere keren te fitten op de monitoringsdata. Dit geeft elke keer een ander modelresultaat, waarbij de verschillen verwaarloosbaar klein moeten zijn voor een betrouwbaar model. GBRT en MLP slaagden glansrijk voor deze test (zie de gemiddelde absolute afwijkingen in Tabel 1). De gemiddelde absolute afwijking voor alle scenario's is kleiner voor GBRT dan voor MLP, wat betekent dat GBRT-voorspellingen minder variaties bevatten en dus stabielere voorspellingen opleveren.

De hoogste verklaarde variantie ($R^2 = 0,950$) is behaald voor de 1-dag-vooruit voorspelling van GBRT (Afbeelding 4A). Dit scenario is daarom gekozen als referentiescenario, waarmee de andere scenario's vergeleken worden. Het basisscenario voor MLP is weergegeven in Afbeelding 4B en heeft een iets lagere verklaarde variantie ($R^2 = 0,885$). De nauwkeurigheid voor het voorspellen van de pieken is nog altijd zeer hoog, maar juist bij een constante waterstand neemt deze af. De verwachting geeft een te sterke daling van de waterstand. Doordat elke dag de laatste gemeten waterstand wordt opgelegd leidt dit tot een 'zaagtand'. Het optreden van dit fenomeen verschilt erg per voorspelling. De daling van de waterstand is de belangrijkste reden voor de hogere waarde van de gemiddelde absolute afwijking van de MLP-voorspelling.

In Afbeelding 4C is de GBRT-voorspelling voor drie dagen vooruit weergegeven. De pieken worden zeer accuraat voorspeld en de belangrijkste reden voor de lagere verklaarde variantie ($R^2 = 0,800$) ten opzichte van het basis scenario is dat de voorspelling niet iedere dag gecorrigeerd wordt, maar slechts iedere drie dagen.


Ten slotte is in Afbeelding 4D de directe GBRT-waterstandsvoorspelling weergegeven. Deze voorspelling vertoont een grilliger patroon in vergelijking met het basisscenario, waarin de voorspelde verandering van de waterstand opgeteld is bij de waterstand van de voorgaande tijdstap. Ook wordt de val van de hoogwatergolf na de piekwaterstanden minder accuraat voorspeld voor de directe GBRT-waterstandsvoorspelling. Het voorspellen van de waterstandsverandering en het meenemen van neerslagvertragingen tot twee dagen waren de twee belangrijkste verbeteringen voor het verkrijgen van meer accurate waterstanden. Het meenemen van neerslagvertragingen was nodig vanwege de trager reagerende grondwatercomponent.



Afbeelding 4 Waterstandsvoorspelling 1 dag vooruit op basis van de waterstandsverandering (GBRT, panel A; MLP, panel B) en de directe voorspelling (GBRT, panel D). Waterstandsvoorspelling 3 dagen vooruit op basis van de waterstandsverandering (GBRT, panel C). De achtergrondkleuren geven de gemiddelde absolute afwijking weer.

Tabel 1 Samenvatting van de meest relevante resultaten van de algoritmes: GBRT en MLP.

Scenario's met 1 dag vooruit voorspelling, tenzij anders aangegeven (met neerslag, vertragingen, temperatuur en maand als input data)	GBRT		MLP	
	Gem. R^2 uit 5 tests	Gem. absolute afwijking (m)	Gem. R^2 uit 5 tests	Gem. absolute afwijking (m)
Directe waterstandsvoorspelling	0,899	0,002	0,863	0,019
Basis voorspelling voor 1 dag vooruit	0,950	0,000	0,885	0,029
Basis voorspelling voor 3 dagen vooruit	0,800	0,006	0,422	0,181
Basis voorspelling (1 dag vooruit) zonder gebiedsneerslag	0,940	0,002	0,931	0,005
Basis voorspelling (1 dag vooruit), zonder vertragingen in de neerslag	0,647	0,001	0,657	0,021



Afbeelding 5 Vergelijking van de directe waterstand voorspelling (WH) met de verandering van de waterstand (WH').

Tabel 1 laat zien dat een langere voorspellingsperiode leidt tot een afname van de verklaarde variantie van de voorspelling. Deze relatie is uitgebreider onderzocht voor zowel de directe waterstandsvoorspelling als voor de voorspelde verandering van de waterstand, waarvan de resultaten zijn weergegeven in Afbeelding 5. De voorspelde waterstanden zijn dus accurater indien de voorspellingsperiode beperkt is, waarbij maximaal drie dagen aangegeven wordt. Dit komt omdat de verandering bij de laatst gemeten

waterstand wordt opgeteld en daarom neemt de fout toe bij langere voorspellingsperiodes.

Discussie

Bij de eerste testberekeningen gaven LSTM en ARIMA minder accurate voorspellingen en daarom zijn deze algoritmes niet verder onderzocht. Met LSTM zijn in andere disciplines goede resultaten behaald (Sutskever e.a., 2014; Vinyals e.a., 2015; Venugopalan e.a., 2015). LSTM heeft echter veel invoerparameters die vergaand geoptimaliseerd kunnen worden. Het is mogelijk dat met uitgebreidere parameteroptimalisatie betere resultaten behaald kunnen worden.

Verscheidene studies hebben ARIMA gebruikt voor het modelleren van neerslag-afvoerrelaties (Brocca e.a., 2013; Gharde e.a., 2016; Nigam e.a., 2014), maar hierbij was de focus slechts op dagelijkse of maandelijkse basis. Ook in deze studie zijn positieve resultaten bereikt voor wat betreft voorspellingen op deze tijdsfrequentie, maar niet voor dynamische (meerdere tijdstappen vooruit) voorspellingen. Het ARIMA-model vereist echter een redelijk constant verloop over de tijd, wat inderdaad op dagelijkse en maandelijkse basis het geval is voor de waterstanden. Het voorliggend onderzoek focust juist op de uurlijkse fluctuaties.

De GBRT-parameter optimalisatie is alleen uitgevoerd voor het basisscenario. De geoptimaliseerde parameters zijn vervolgens voor alle GBRT-scenario's gebruikt om de resultaten zuiver met elkaar te kunnen vergelijken. Echter, het valt te betwisten of dit daadwerkelijk de beste vergelijking oplevert. De invoergegevens voor de verschillende scenario's verschillen immers en dat zal ook betekenen dat de optimale parameters voor elk scenario afwijken. Voor een voorspelling voor drie dagen vooruit zullen bepaalde parameters meer of minder meewegen, waarmee de optimale parameterinstelling dus anders is. Wanneer voor elk scenario opnieuw een parameteroptimalisatie wordt gedaan, zullen die geoptimaliseerde scenario's waarschijnlijk beter presteren dan uit deze verkennende studie blijkt.

De beste resultaten voor het MLP-algoritme zijn niet voor het basisscenario verkregen, maar voor het scenario zonder gemiddelde gebiedsneerslag. Dit scenario gaf ook voor de GBRT een nauwkeuriger resultaat. Wel werden er kleine verbeteringen in de nauwkeurigheid van de voorspellingen gevonden wanneer parameters als bijvoorbeeld verdamping werden toegevoegd. Het toevoegen van verdamping was vooral belangrijk voor het accuraat voorspellen van de val van de hoogwatergolven. De potentiële verdamping werd berekend aan de hand van temperatuur en globale straling, wat de sterke relatie tussen waterstandsval en verdamping verklaart; dit ten opzichte van alleen temperatuur en waterstandsvalingen.

Conclusies en aanbevelingen

De resultaten van dit onderzoek laten zien dat Machine Learning algoritmes kunnen worden gebruikt voor het voorspellen van waterstanden voor de meetlocatie Blauwe Kamer in de Bovenmark, bovenstrooms van Breda. In dit onderzoek zijn de meest nauwkeurige resultaten bereikt met de Gradient Boosting Regression Trees (GBRT) methode. De beste resultaten zijn gevonden voor verwachtingen voor 24 uur vooruit (R^2 waarde van 0,95 en een gemiddelde absolute fout van 0,022 m), met als invoerparameters gemiddelde gebiedsneerslag, neerslag van KNMI-station Gilze Rijen (beide met vertragingen tot en met twee dagen), temperatuur, maand en uur van de dag. De resultaten voor GBRT waren iets beter dan de MLP-resultaten, inclusief de variatie tussen de verschillende voorspellingen (zie Tabel 1). GBRT en Machine Learning-algoritmes in meer algemene zin lijken daarmee een alternatief voor het gebruik van simulatiemodellen voor het opstellen van waterstandsverwachtingen.

Het opzetten van een neuraal netwerk is ingewikkelder dan het opzetten van een ARIMA of GBRT-model, omdat meer parameters geoptimaliseerd moeten worden en de werking van het model door het "Black-Box"-principe gecompliceerder is. De opbouw van het Machine Learning model (ML-model), de data-analyse, het selecteren en geschikt presenteren van de data en de model-parameteroptimalisatie, vergen relatief veel tijd. De tijdsduur hangt sterk af van de gewenste nauwkeurigheid, de hoeveelheid beschikbare data en de kwaliteit van de dataset. Zodra het model opgezet is, werkt het ML-model zeer snel. De rekentijd voor waterstandsvoorspellingen van een tot drie dagen vooruit, voor locatie Blauwe Kamer, bedraagt enkele seconden. Het hele model opnieuw trainen op basis van nieuw beschikbare data vergt enkele minuten. Daarom is een ML-model geschikt om continue betrouwbare waterstandsvoorspellingen te maken op basis van de meest recente data. Een aandachtspunt hierbij is wel dat een ML-model gebaseerd is op meetdata. Dit is een

groot voordeel omdat geen schematisatie nodig is, maar het boet aan betrouwbaarheid in bij grote veranderingen in het watersysteem, zoals bijvoorbeeld waterdiepte-aanpassingen. Dit omdat de meetdata voor en na de ingreep immers verschillen, vanwege de verschillen in het bemeten systeem.

In een mogelijk vervolgonderzoek zou het interessant zijn om de betrouwbaarheid van de Machine Learning resultaten te vergelijken met SOBEK-resultaten voor dit watersysteem. Daarnaast zou het waardevol zijn om de neerslagvoorspellingen te gebruiken als testdataset in plaats van de werkelijk gemeten neerslag, omdat dit ook een fout met zich meebrengt. Indien een langere voorspellingsreeks beschikbaar is, zou het algoritme ook getraind kunnen worden op neerslagvoorspellingen met bijbehorende onzekerheden erin.

Verder is het belangrijk om andere locaties te testen, om te onderzoeken of vergelijkbare resultaten worden behaald. Ook zou het toevoegen van grondwaterparameters verder onderzocht kunnen worden.

Literatuur

- Brocca, L., Liersch, S., Melone, F., Moramarco, T. en Volk, M. (2013).** Application of a model-based rainfall-runoff database as efficient tool for flood risk management; in: *Hydrology and Earth System Sciences*, pag 3159-3169.
- Brownlee, J. (2017).** How to Create an ARIMA Model for Time Series Forecasting with Python. *Machine Learning Mastery*: <https://machinelearningmastery.com/arima-for-time-series-forecasting-with-python/>
- Colton, S. (2004).** Lecture 13: Multi-Layer Artificial Neural Networks. *Imperial College London*: <https://www.doc.ic.ac.uk/~sgc/teaching/pre2012/v231/lecture13.html>
- Fayyad, U., Piatetsky-Shapiro, G. en Smyth, P. (1996).** From data mining to knowledge discovery in databases; in: *AI Magazine*, pag 37-54.
- Gharde, K.D., Kothari, M. en Manhale, D.M. (2016).** Developed seasonal ARIMA model to forecast streamflow for Savitri basin in Konkan region of Maharashtra on daily basis; in: *Journal of the Indian Society of Coastal Argicultural Research*, pag 110-119.
- Jain, A. (2016, February 21).** Complete Guide to Parameter Tuning in Gradient Boosting (GBM) in Python. *Analytics Vidhya*: <https://www.analyticsvidhya.com/blog/2016/02/complete-guide-parameter-tuning-gradient-boosting-gbm-python/>
- Nigam, R., Nigam, S. en Mittal, S.K. (2014).** Modeling tropical river runoff: A time dependent approach; in: *Science in cold and arid regions*, pag 247-256.
- Sutskever, I., Vinyals, O. en Le. Q.V. (2014).** Sequence to sequence learning with neural networks; in: *Proc. Advances in Neural Information Processing Systems 27*, pag. 3104-3112.
- Venugopalan, S., Rohrbach, M., Donahue, J., Darrell, T. en Saenko, K. (2015).** *Sequence to Sequence video to text*; in: Proc. ICCV.
- Vinyals, O., Toshev, A., Bengio, S. en Erhan, D. (2014).** Show and tell: a neural image caption generator; in: *Proc. International Conference on Machine Learning*.
- Yufeng, G. (2017, August 31).** The 7 steps of machine learning. *Towards Data Science*: <https://towardsdatascience.com/the-7-steps-of-machine-learning-2877d7e5548e>

Summary Innovative machine learning for water management:

A case study for Regional Water Authority Brabantse Delta

Rapid advancements in machine learning have made this data analysis methodology a feasible and cost-effective alternative to manual hydrological and hydrodynamic programming. In this study, the feasibility of machine learning in operational water management is tested by means of predicting water levels within a relatively small Belgium-Dutch catchment. Gauging station Blauwe Kamer in the transboundary Bovenmark catchment was selected as study location, which is under the supervision of Regional Water Authority Brabantse Delta. The Regional Water Authority provided historical data, which has been used to investigate the performance of four different machine learning algorithms; Autoregressive Integrated Moving Average (ARIMA), Gradient Boosting Regression Trees (GBRT), Long Short-Term Memory (LSTM) and Multi-Layer Perceptron (MLP) Artificial Neural Networks. GBRT and MLP seemed to be the most promising algorithms to predict water levels. Moreover, predicting water level changes and transforming those back into water levels resulted in more accurate results, due to the strong relation between precipitation and alterations within the water levels. The best results were obtained with GBRT for which an average R^2 of 0.95 for a one day ahead prediction and an average R^2 result of 0.80, with an average absolute deviation of 0.006 m for a forecast for 3 days. Furthermore, test results showed that adding parameters like weir crest levels and evaporation did not improve the accuracy for GBRT, while small improvements were achieved for MLP (approx. 1%). Remarkably, ground water levels did not improve the GBRT-model performance, but this could be the result of a smaller training set or because precipitation delays already indirectly cover for ground water level dynamics. The accuracy of the models was found to be highly dependent on the forecast window, but in general higher accuracies and smaller deviations were achieved with the GBRT model.

Auteurs

DORIEN HONINGH

Stagiair Witteveen+Bos (Watermanagement student, TU Delft), Delft
D.F.Honingh@student.tudelft.nl

JELLE DE JONG

Witteveen+Bos, thans Waterschap Drents Overijsselse Delta
jelledejong@wdodelta.nl

BRAM BLOKS

Witteveen+Bos, Amsterdam
bram.bloks@witteveenbos.com

HERMAN MONDEEL

Witteveen+Bos, Rotterdam
herman.mondeel@witteveenbos.com

KLAAS-JAN DOUBEN

Waterschap Brabantse Delta, Breda
k.douben@brabantsedelta.nl

