




# Eindrapportage ReRengAI Project

DEEP – Anna Stalknecht, Bart von Meijenfeldt en Sjoerd Gnodde

*april – september 2021*

# Inhoud

Probleemschets.....	3
Watersysteem beheer Delfland.....	3
SOBEK.....	3
Technische inrichting.....	3
Machine Learning.....	3
Onderzoeksvraag.....	4
Achtergrond project.....	5
Naamgeving project.....	5
DEEP.....	5
Projectteam.....	5
Inventarisatie.....	6
Data.....	6
BOS-FEWS.....	6
Azure Machine Learning.....	6
Modellen.....	7
Neural Network model.....	7
LGB model.....	7
Lineaire Regressie (Ridge).....	7
ReRengAI.....	7
Resultaten.....	8
Algemene score.....	8
Vergelijking ReRengAI - SOBEK.....	9
Implementatie.....	11
Samenwerking met HKV.....	11
Toekomst.....	12
Conclusie.....	13



## Probleemschets

Dit project speelt zich af in het volgende spectrum:

### Watersysteem beheer Delfland

Het watersysteem van Delfland werkt globaal als volgt:

Vanuit de polders wordt overtollig (regen)water naar de boezem verpompt. Dit gaat op basis van een relatief vast inslagpeil. Het water kan het gebied weer uit met een aantal grote boezemgemalen.

Tegelijkertijd wordt er via een groot gemaal onder de Nieuwe Waterweg door en een sluis bij Leidschendam extra water het gebied in gelaten, dat soms ook weer de polders wordt ingelaten.

Het water op de boezem wordt geregeld met een RTC tools model, die op basis van voorspellingen het niveau binnen een marge probeert te houden.

De voorspellingen zijn onder andere

- Verpompt debiet vanuit de polders (of over een stuw)
- Neerslag direct op de boezem
- Inlaten richting de polders (deze worden niet bemeten)

Dit alles wordt berekend door een SOBEK RR model, waarbij het debiet vanuit de polders het belangrijkste is.

### SOBEK

Het SOBEK RR model bepaalt eens per 10 minuten op basis van hydrometeorologische

parameters het debiet naar of vanuit de boezem (ook als is dat laatste bijna niet te voorspellen).

Het SOBEK RR model heeft een drietal nadelen:

- Vanwege de snelheid waarmee deze berekening moet gebeuren, zijn de 94 afvoergebieden versimpeld tot 25 gebieden, waarvan 'alle pompen aan dan wel uit staan'. Dit zorgt ervoor dat het debiet meestal ruim overschat of onderschat wordt.
- Omdat het bodemvocht expliciet wordt gebruikt in het model, maar niet bemeten wordt, moet deze door het jaar heen aan de hand van hydrologische parameters bijgehouden worden. Hoe verder in het hydrologische jaar, hoe meer dit getal uit de pas loopt met waarheid
- Er is geen uitputtend onderzoek geweest naar alternatieven voor het SOBEK model

Het SOBEK RR model heeft natuurlijk ook voordelen. Die worden hier niet behandeld.

### Technische inrichting

Het geheel (data verwerking, SOBEK voorspelling en RTC tools optimalisatie) wordt aangestuurd door een FEWS instantie.

### Machine Learning

Op dit moment is machine learning<sup>1</sup> sterk in opkomst. Machine learning is een discipline die de focus legt om algoritmes te creëren die zelf kunnen leren uit data. Machine Learning is een

<sup>1</sup> Zie <https://www.youtube.com/watch?v=PeMlggyqz0Y> voor een beknopte uitleg wat machine learning is

sub-discipline van Artificial Intelligence. Machine learning is een goede methode om gemakkelijk algoritmen te maken die zaken kunnen voorspellen in tal van toepassingen, die ook nog eens snel uitvoerbaar zijn.

## Onderzoeksvraag

Gegeven de huidige regeling, de gebreken van het SOBEK model en de mogelijkheden van machine learning, is het doel van dit project is om een machine learning model te maken dat uit de historische data patronen leert om zo te kunnen voorspellen wat het debiet in de toekomst zal zijn.

Dit model doet voorspellingen voor alle losse gemalen en met hetzelfde interval van 10 minuten als het huidige SOBEK model. Daarnaast moet het ook voorspellingen doen voor de komende 36 uur met voorspel intervallen van 5 minuten.

Ook wordt er getest of dit model ook in de huidige FEWS straat past.

## Achtergrond project

### Naamgeving project

Om het project herkenbaar te maken, is er een naam aan gehangen: *ReRengAI*. Dit is als volgt opgebouwd:

- Rerenga = neerslag in het Maori
- Hoofdletter R 2x staat voor Rainfall Runoff. Het gemaakte model is een zogenaamd rainfall runoff (neerslag afvoer) model.
- AI = artificial intelligence, staat voor het gebruik van machine learning in het project

### DEEP

Dit project vond plaats in kader van het DEEP (Data science en Engineering Expert Programma) project, waarin data scientists en data engineers binnen de waterschapswereld in een jaar worden opgeleid. Er waren twee opdrachtrondes met steeds twee opdrachten, waar de DEEP deelnemers samen steeds drie dagen per week mee bezig waren.

### Projectteam

Het projectteam bestond uit:

#### Kernteam

<b>Wie</b>	<b>Bijdrage</b>	<b>Functie</b>	<b>Waterschap</b>	<b>E-mailadres</b>
Sjoerd Gnodde	Data, projectleider	Data scientist	HH Delfland	<a href="mailto:sgnodde@hhdelfland.nl">sgnodde@hhdelfland.nl</a>
Bart von Meijenfeldt	Model, AzureML	Data scientist	WDODelta	<a href="mailto:bartvonmeijenfeldt@wdodelta.nl">bartvonmeijenfeldt@wdodelta.nl</a>
Anna Stalknecht	FEWS omgeving, AzureML	Data engineer	Vallei en Veluwe	<a href="mailto:astalknecht@vallei-veluwe.nl">astalknecht@vallei-veluwe.nl</a>

Daarnaast waren ook betrokken:

Marc Advocaat - Business owner

Jeroen den Ouden - Product owner

Jochem Fritz - Domein expert (hydroloog)

Silvio Zeeman - Domein expert (peilbeheerder)

# Inventarisatie

## Data

<i>Naam</i>	<i>Bron</i>	<i>Interval</i>	<i>Opmerkingen</i>
<i>Debieten gemalen en stuwen</i>	WIS	5 min	
<i>Waterhoogtes</i>	WIS	5 min	
<i>Neerslagmeters Delfland</i>	WIS	15 min	
<i>Neerslagradar</i>	Hydronet	10 min	
<i>Neerslagvoorspellingen*</i>	DTN	Uur	Historische data hebben we zelf niet en bij DTN is het erg duur
<i>Tijd van het jaar*</i>	Alle data		
<i>Potentiële verdamping*</i>	KNMI	Dag of uur	

\* Niet gebruikt in het huidige model

Van deze databronnen zijn weer andere features gemaakt, zoals de gemiddelde waterstand van het afgelopen uur.

## BOS-FEWS

In BOS-FEWS worden op dit moment al de belangrijkste parameters opgehaald.

## Azure Machine Learning

We hebben het Azure Machine Learning platform van het Waterschapshuis gebruikt om

de modellen te creëren. Voordelen van dit platform is dat het bedoeld is voor Machine Learning en daarom netjes alle relevante informatie van een experiment<sup>2</sup> op een plek zet. Ook is het handig dat het op een centrale plek staat dus dat alle ontwikkelaars de resultaten van alle experimenten kunnen zien. Deze experimenten en een uitdraai van de data staan in de Azure Machine Learning Workspace "ml\_rainfall\_runoff" op de Waterschapshuis Azure omgeving.

---

<sup>2</sup> In deze context een stukje code dat wordt uitgevoerd om modellen te creëren. Vaak worden relevante metrics ook bijgehouden om

te kijken of het experiment succesvol is geweest (beter dan de vorige ontwikkelde modellen).

## Modellen

### Neural Network model<sup>3</sup>

Initieel hadden we de voorkeur om een Neural Network te gebruiken als ons voorspellend model. Het grote voordeel is dat we dan per locatie een model maar nodig hebben dat direct voor de komende 36 uur per 5 minuten alle benodigde voorspellingen (432 in totaal) kan maken. Dit bespaart zowel computerkracht tijd in het ontwikkelen van de modellen en zou het de FEWS server minder belasten wanneer die elke 10 minuten de voorspellingen maakt. Uiteindelijk bleek dat de voorspellende kracht van dit type model slecht werkte voor deze casus. Daarom hebben we uiteindelijk besloten om dit type model niet te gebruiken.

### LGB model<sup>4</sup>

Daarom hebben we ervoor gekozen een LGB modellen te gebruiken. Het grote voordeel hiervan was dat de voorspellende kracht stukken hoger is dan het neurale netwerk, vooral de eerste paar uur presteert het heel goed. Het nadeel is dat je per locatie per tijdstip dat je vooruit wilt voorspellen nu een uniek model moet creëren. Omdat je nu 432 modellen nodig hebt, gaat hierdoor de benodigde compute resources omhoog elke keer als je een voorspelling wilt maken. Omdat het LGB model vooral beter presteert in de eerste uren, en dat deze het belangrijkste zijn hebben we besloten om voor de eerste 6 uur de voorspellingen. Hierdoor is de benodigde compute resources

beperkt gebleven maar hebben we alsnog de voorspellende kracht van het model op de belangrijkste momenten verbeterd.

### Lineaire Regressie (Ridge)

De laatste 30 uur voorspellen we met een klassiek statistisch model, een lineaire regressie. Verder vooruit werd het minder belangrijk om een complex machine learning model te gebruiken en presteert dit simpelere model vergelijkbaar. Groot voordeel is dat dit model erg snel zijn berekeningen kan maken, wat compenseert voor de slomere LGB modellen. Specifiek gebruiken we een Ridge Regression wat de coëfficiënten van het lineaire model op zo'n manier leert dat het (meestal) beter geschikt is voor voorspellingen maken.

### ReRengAI

Zoals in de vorige kopjes uitgelegd bevat ons model 432 sub-modellen om over 36 uur per 5 minuten een voorspelling te kunnen maken. Elk van deze sub-modellen is verantwoordelijk om op een specifiek tijdstip de debietvoorspellingen te maken. Voor de eerste 6 uur gebruiken we 72 LGB modellen en voor de overige 30 uur gebruiken we 360 lineaire regressie modellen.



<sup>3</sup> Een complex black box model dat erg flexibel is en meerdere voorspellingen tegelijk kan maken.

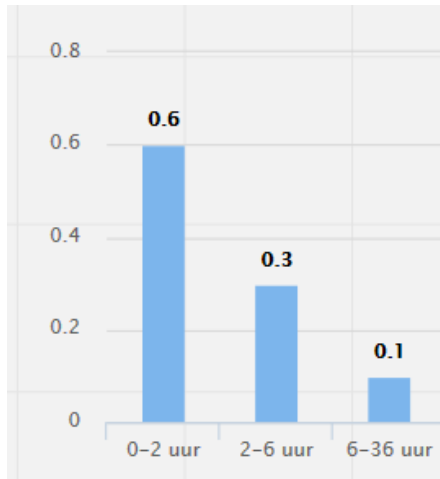
<sup>4</sup> De implementatie van microsoft van een gradient boosting machine, een complex

black box model met hoge voorspellende kracht dat makkelijker te optimaliseren is.

# Resultaten

## Algemene score


Met name voor de zogenaamde hyperparameteroptimalisatie, is er een enkele score gemaakt die de alle horizonnen en alle voorspellingen combineert. Eerst wordt er een NSE<sup>5</sup> uitgerekend per horizon en dan worden alle NSEs per onderstaand vak gecombineerd en geschaald maal de staafgrootte.



Hiermee kom je uit op een cijfer waarbij de eerste voorspellingen veel belangrijker zijn. Gemiddeld kwamen we bij een selectie gemalen uit op een waarde van 0.69.

Hieronder staan nog een aantal afbeeldingen hoe het debiet er uit ziet (debiet is eigenlijk in  $m^3/min$ ) voor verschillende horizonzen:

### Poldergemaal Spangen

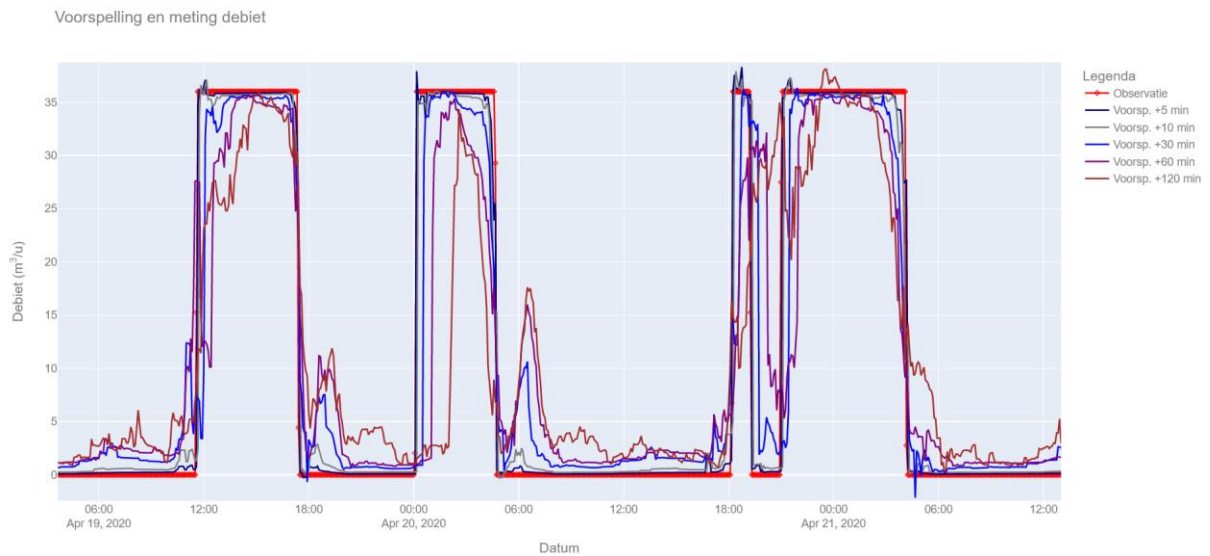


Het model ziet hier van tevoren aankomen dat de pomp aan gaat. Het continue karakter (i.p.v. binair aan/uit) van de voorspellingen zouden wel eens erg nuttig kunnen zijn als ze uitgemiddeld worden over meerdere gemalen.

<sup>5</sup> [https://en.wikipedia.org/wiki/Nash%E2%80%93Sutcliffe\\_model\\_efficiency\\_coefficient](https://en.wikipedia.org/wiki/Nash%E2%80%93Sutcliffe_model_efficiency_coefficient)




## Gemaal van de Eshofpolder



Voorspellingen zijn weer vrij goed, soms ook wat minder, maar de pomp gaat wel met grote regelmaat aan hier.

## Gemaal van de Holierhoekse- en Zouteveensepolder



Voorspellende kracht is hier niet zo groot: het model baseert de toekomst vooral op de huidige waarde.


## Vergelijking ReRengAI - SOBEK

Als je het SOBEK RR model met het ReRengAI model vergelijkt, zie je inderdaad de hoge, korte pieken die het SOBEK model voorspelt. Tijdens dit onderzoek is er alleen voor node 64 van het FEWS-BOS (Ypenburg en omgeving) een vergelijking gemaakt. Dit is toevallig een gebied geweest waarbij zowel de SOBEK-voorspelling als het ReRengAI model het relatief slecht deden. Toch is duidelijk dat het ReRengAI model veel dichter bij het werkelijke debiet zit.


Als je dan naar de NSE kijkt, zie je dat die niet heel hoog is bij ReRengAI, maar dat het SOBEK model werkelijk dramatisch presteert. Dit komt omdat de hoogte van de piek vaak slecht voorspeld is.

Wij verwachten dat het beeld op andere plekken vergelijkbaar is, waarbij beide modellen wel beter presteren.

Voorspelling en meting debiet



## NSE



Er is voor dit gebied ook gekeken naar een 'waterbalans', dat wil zeggen, hoeveel debiet schatten de beide modellen in totaal over een periode van twee weken, en hoeveel was het echt. Hier is duidelijk dat de modellen ook hier slecht presteren (waarschijnlijk door de locatie, op andere plekken leek het beter te zijn, maar daar is nu geen meer data van beschikbaar). Echter presteert het machine learning niet slechter, zelfs ietsje beter dan het SOBEK model.

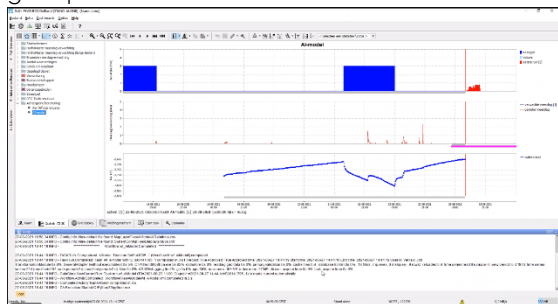
SOBEK 10360.113120 m<sup>3</sup>

actual 6128.720000 m<sup>3</sup>

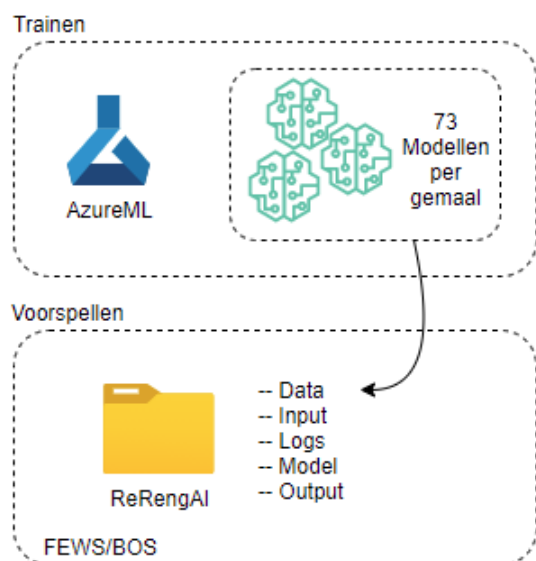
ReRengAI 9494.636628 m<sup>3</sup>

## Implementatie

Om de eindgebruiker mee te nemen in het succes van ons model is bij de start van het project de wens uitgesproken het model real time te laten meedraaien in het BOS/FEWS systeem. De resultaten van het model hebben geen invloed op het RTC-Tools model, wat na de voorspelling de gemalen aanstuurt, maar de eindgebruiker kan wel zien wat de voorspelling van ReRengAI is ten opzichte van SOBEK. Hiervoor moest ons model dus net als SOBEK geïmplementeerd worden in FEWS.



Aanvankelijk is bedacht om het volledige model te draaien in de Azure cloud, en de resultaten van het model d.m.v. een API te visualiseren in het BOS. Dit is zeker geen problematische oplossing maar in gesprekken met de beheerders van het BOS kwamen we erachter dat het systeem juist erg geschikt is om Machine Learning modellen te draaien en is hierdoor flexibeler. Om de systemen alsnog niet te belasten is er wel voor gekozen om het trainen in Azure te laten. Hierbij komen we bij de volgende implementatie:



Het model zal na training in Azure handmatig in FEWS worden gezet volgens een vooropgezette mappenstructuur die hierboven te zien is. De invulling van de mappen ziet er als volgt uit:

- Data
  - LOCATIEID: Bevat de modellen voor die locatielD
  - 2 vertaalbestanden van de pompen/gemalen
- Input: Door FEWS klaargezette data: debieten, waterstanden en neerslagdata
- Logs: Door het script gegenereerde logging
- Model: Hierin staat de runscript voor het model en extra scripts waar in de run gebruik van wordt gemaakt
- Output: Output gegenereerd door het model die weer gelezen kan worden door FEWS

## Samenwerking met HKV

Voor de implementatie van dit project zal altijd de samenwerking opgezocht moeten worden met HKV omdat zij beschikken over de juiste toegang tot de machines die de berekeningen uitvoeren voor het BOS en eerder succesvol modellen hebben geïmplementeerd in het systeem. Zolang de input data die ons model verwacht hetzelfde blijft zal, na het succesvol implementeren van het huidige model, de implementatie van een nieuw getraind model niet veel extra tijd kosten. Voor de toekomst loont het wel om te kijken naar een andere manier van implementeren. In de huidige manier van implementeren gaat FEWS 1 voor 1 over alle locaties waarna het model voor die locatie wordt gedraaid. In de toekomst zou het efficiënter kunnen zijn om in 1 keer de data van alle locaties klaar te zetten en de modellen, eventueel parallel, te draaien.

# Toekomst

Er is nog een aantal verbeterlagen dat toegepast *kan* worden, samen met wat andere nuttige werkzaamheden:

- 1) Het afronden van het huidige model
  - a) De code in BOS-FEWS ietwat opschonen
  - b) Alle gemalen toevoegen aan BOS-FEWS
  - c) Debieten terugmappen naar RTC Tools nodes
- 2) Het opstarten van een uitgebreide evaluatieperiode, waarbij
  - a) De voorspellingen in een tabblad in BOS-FEWS live gevalideerd kunnen worden en we feedback van de peilbeheerders mee kunnen nemen
  - b) Een uitgebreide analyse doen van de resultaten met een hydroloog
- 3) Het model verder verbeteren
  - a) Uitgebreide hyperparameter optimalisatie
  - b) Features toevoegen
    - i) Verdamping (of dat soort parameters)
    - ii) Toekomst toevoegen
    - iii) Andere weersgegevens?
    - iv) Tijd van het jaar
  - c) Huidige features aanpassen/verwijderen: die kunnen ook wat verder geëvalueerd worden
  - d) Features die langer teruggaan maken en state files hiervoor gebruiken
  - e) Eventueel: classificatiemodel testen
- 4) Code verbeteren
  - a) Unittest maken op code in BOS-FEWS
  - b) Code efficiënter/sneller laten runnen
- 5) Uitleg geven aan stakeholders

## Conclusie

Het ReRengAI model presteert een stuk beter dan het SOBEK RR model en kan daarnaast ook prima toegepast worden in BOS-FEWS. Het advies is daarom om het SOBEK RR model op den duur te vervangen voor dit of een vergelijkbaar machine learning model. Wel is het zo, dat dit advies eerst uitgebreid gevalideerd zal

moeten worden, zowel hydrologisch als in de dagelijkse praktijk.

Daarnaast zijn er nog een aantal verbeterlagen nodig op het model, zodat deze zo optimaal mogelijk is.