

## Toepassing SchemaGAN in een Digital Twin Verkenning aan de hand van de Digital Twin ARK

### Auteur(s)

Fabian Campos Montero

Chris Bremmer

Kin Sun Lam





## Toepassing SchemaGAN in een Digital Twin

### Verkenning aan de hand van de Digital Twin ARK

<b>Opdrachtgever</b>	Rijkswaterstaat Water, Verkeer en Leefomgeving
<b>Contactpersoon</b>	Linneke van der Veeke
<b>Projectreferenties</b>	
<b>Trefwoorden</b>	Digital Twin, Kunstmatige Intelligentie, AI, SchemaGAN, ondergrond waterkering

#### Documentgegevens

<b>Versie</b>	1.0
<b>Datum</b>	22-12-2025
<b>Projectnummer</b>	11211566-007
<b>Document ID</b>	11211566-007-ZWS-0001
<b>Pagina's</b>	32
<b>Classificatie</b>	
<b>Status</b>	Definitief

#### Auteur(s)

	Fabian Campos Montero Chris Bremmer Kin Sun Lam	

# Samenvatting

In 2025 is in het kader van het project Versterking Onderzoek Waterveiligheid nader onderzoek gedaan naar . De toepassing van een Generative Adversarial Network (GAN) voor het geautomatiseerd genereren van ondergrondprofielen als invoer voor de stabiliteitsberekeningen van de Digital Twin ARK. Hiervoor is de SchemaGAN-applicatie gebruikt en verder uitgebreid.

Op grond van dit onderzoek wordt geconcludeerd dat AI-gebaseerde ondergrondschematisatie een haalbaar hulpmiddel voor geotechnische beoordeling van waterkeringen, vooral in vroege stadia. SchemaGAN kan consistente, realistische ondergrondschematisaties genereren over lange trajecten en biedt een solide basis voor initiële evaluatie en screening. De belangrijkste meerwaarde is de expliciete identificatie van onzekerheid en aandachtsgebieden. Door te tonen waar interpretatie sterk afhankelijk is van lokale data, ondersteunt SchemaGAN gerichte onderzoeksplanning en beter onderbouwd technisch oordeel. De aanpak ondersteunt maakt het mogelijk om snel modellen ondergrond modellen te maken en te updaten waardoor het geautomatiseerd doorrekenen van stabiliteitsanalyses in een Digital Twin mogelijk wordt.

# Inhoud

	<b>Samenvatting</b>	<b>4</b>
	<b>Inhoud</b>	<b>5</b>
<b>1</b>	<b>Inleiding</b>	<b>6</b>
<b>2</b>	<b>AI gegenereerd ondergrond model – SchemaGAN</b>	<b>7</b>
2.1	Waarom AI nuttig is voor ondergrond modellering	7
2.2	Hoe Generatieve Modellen kunnen helpen om de ondergrond te schematiseren	7
2.3	Wat SchemaGAN doet	8
2.3.1	Wat het model leert	8
2.3.2	Hoe het model in de praktijk werkt	9
2.3.3	Aannames en beperkingen	10
2.4	Wat we in dit project willen bereiken	10
<b>3</b>	<b>AI voor ARK</b>	<b>11</b>
3.1	Case study – Digital Twin ARK	11
3.2	Toepassing van SchemaGAN in Digital Twin ARK	13
3.2.1	Betuwepand-casestudy	13
3.2.2	Baseline SchemaGAN-schematisatie	14
3.2.3	Verbeteringen geïntroduceerd in dit project	15
3.2.4	Resulterende ondergrondschematisaties	16
3.2.5	Onzekerheid en aandachtspunten	18
3.2.6	Kwalitatieve vergelijking met de huidige praktijk	20
<b>4</b>	<b>Discussie en Conclusies</b>	<b>24</b>
<b>5</b>	<b>Referenties</b>	<b>26</b>
<b>A</b>	<b>Strategie voor verbeterde resolutie en segmentering</b>	<b>27</b>
<b>B</b>	<b>Schatting van modelonzekerheid met behulp van Monte Carlo-dropout</b>	<b>28</b>
<b>C</b>	<b>Ruimtelijke (epistemische) onzekerheid en leave-out-validatie</b>	<b>29</b>
<b>D</b>	<b>Beeldverbeteringsmethoden (niet toegepast)</b>	<b>31</b>

# 1 Inleiding

In het kader van het project 'Verkennd Onderzoek Waterveiligheid' is er in 2024 onder een aantal stakeholders een nadere verkenning uitgevoerd naar de beelden en wensen die er leven ten aanzien van Digital Twins. Hiervoor is een kennissessie uitgevoerd aan de hand waarvan inzicht is verkregen in behoeften en het belang van functionaliteiten van een Digital Twin voor waterkeringen (Deltares, 2024a). Naast deze behoefteverkenning is er een toekomstverkenning uitgevoerd. Op grond hiervan is geconcludeerd dat een nadere verkenning en het toepasbaar maken van AI en remote sensing in een concrete case wenselijk is om zo beter inzichtelijk te maken op welke wijze AI en Remote sensing een bijdrage kunnen leveren aan het ontwerp en beheer van waterkeringen (Deltares, 2024b). De beoogde impact is een verbeterde informatiepositie voor de waterkeringbeheerder leidend tot efficiënter ontwerp en beheer van waterkeringen en een betere informatiepositie bij calamiteiten.

Als case wordt gebruik gemaakt van de 'Digital Twin ARK' die ontwikkeld is in het kader van het Corporate Innovation Programma van Rijkswaterstaat en als doel heeft om de verschillende technische aspecten alsmede de waarde van een digital twin voor waterveiligheid te onderzoeken. Deze Digital Twin is gemaakt voor het Betuwepand en is een proof-of-concept gericht op het kunnen integreren van meet- en monitoringinformatie ten behoeve van een continu inzicht in de stabiliteit.

Het onderzoek heeft zich in 2025 gericht op het volgende:

- Toepassen en testen van een Generative Adversarial Network (GAN) voor het geautomatiseerd genereren van ondergrondprofielen als invoer voor de stabiliteitsberekeningen van de Digital Twin
- Verkennen van de toepassing van L-band remote sensing voor het grootschalig in kaart brengen van kwelzones langs waterkeringen

Voor het verkennen van de toepassing van L-band remote sensing voor het grootschalig in kaart brengen van kwelzones langs waterkeringen is een aanvraag gedaan voor satellietbeelden van de SAOCOM-missie. Toestemming voor het gebruik van deze beelden heeft te lang geduurd om nog geanalyseerd te kunnen worden. Daarom is in de loop van het project besloten om het AI-deel uit te breiden. Hierover wordt in onderstaande verslag gedaan.

## 2 AI gegenereerd ondergrond model – SchemaGAN

Het schematiseren van de ondergrond is een fundamentele stap bij het beoordelen en ontwerpen van waterkeringen. Het vormt de basis voor stabiliteitsanalyses, kwelonderzoeken en risicobeoordelingen, maar wordt doorgaans uitgevoerd op basis van beperkte, puntgebaseerde gegevens en leunt sterk op deskundige interpretatie. In dit hoofdstuk wordt ingegaan op de reden om Kunstmatige Intelligentie (AI) te gebruiken voor ondergrondmodellering, en wordt uitgelegd uit hoe generatieve modellen kunnen worden ingezet om ondergrondschematisaties te maken op basis van beperkte data. Tevens wordt nader ingegaan op de SchemaGAN-aanpak die in dit project is toegepast.

### 2.1 Waarom AI nuttig is voor ondergrond modellering

Bij geotechnische projecten is informatie over de ondergrond doorgaans schaars en afkomstig van puntmetingen zoals sonderingen (CPT) en boringen. Ingenieurs moeten deze gegevens interpreteren en extrapoleren om de ontbrekende informatie aan te vullen. Dit proces steunt sterk op hun deskundig oordeel, soms ondersteund door interpolatietools of geostatistische technieken. Dit leidt tot onzekerheid, inconsistenties en een grote tijdsinvestering. Dit geldt in het bijzonder voor grootschalige lineaire infrastructuren zoals waterkeringen.

Kunstmatige Intelligentie (AI), en in het bijzonder Machine Learning (ML), biedt een alternatief door patronen rechtstreeks uit data te leren. Deep learning-modellen kunnen complexe relaties tussen invoer en uitvoer identificeren zonder vooraf gedefinieerde aannames, waardoor ze bijzonder geschikt zijn voor complexe en heterogene ondergrondse omgevingen. In de afgelopen jaren zijn AI-modellen steeds vaker onderzocht voor laagdetectie, interpolatie van eigenschappen en geotechnische classificatie. In deze context moet AI-gebaseerde ondergrondmodellering worden gezien als een hulpmiddel ter ondersteuning van besluitvorming, niet als vervanging van terreinonderzoek of deskundig oordeel. Het doel is niet om één enkele 'ware' ondergrondconfiguratie te voorspellen, maar om consistente en data-geïnformeerde schematisaties te genereren die zowel de beschikbare metingen als de onzekerheid door beperkte data weerspiegelen. Dit onderscheid is vooral belangrijk voor grootschalige lineaire infrastructuren, waar volledige ondergrondinformatie zelden beschikbaar is.

### 2.2 Hoe Generatieve Modellen kunnen helpen om de ondergrond te schematiseren

De meeste conventionele ML-modellen voorspellen waarden op specifieke locaties. Generatieve modellen hanteren een andere benadering: ze proberen de onderliggende structuur van de data te leren en complete representaties te genereren die lijken op die uit de trainingsfase. Generative Adversarial Networks (GAN's) vormen een klasse van deep learning-modellen die werken via een competitie tussen twee neurale netwerken: het ene genereert een kandidaatbeeld, terwijl het andere beoordeelt of dit realistisch oogt. Door deze 'adversarial' training leert de generator na verloop van tijd steeds realistischer representaties te produceren.

Voor de ondergrond moet 'realistisch' niet worden opgevat als een exacte reconstructie van de werkelijke ondergrond, die fundamenteel onbekend is, maar als consistent met aangeleerde geologische en geotechnische patronen. De kracht van GAN's ligt in hun

vermogen om plausibele en samenhangende structuren te genereren die de waargenomen data respecteren en tegelijkertijd plekken waar informatie ontbreekt op een gestructureerde manier opvullen.

Een conditionele GAN (cGAN) breidt dit idee uit door de generatie te sturen met extra informatie als invoerconditie. Voor grondonderzoek zijn in Nederland CPT-gegevens doorgaans de meest overvloedige en informatieve bron van metingen. Een cGAN-model dat wordt geconditioneerd op CPT-data stelt het model in staat om complete ondergrondmodellen te creëren die (i) de gemeten data honoreren en (ii) plausibel interpoleren tussen onderzoekslocaties op basis van patronen die uit trainingsdata zijn geleerd.

De modelprestatie moet daarom niet worden geïnterpreteerd in termen van puntgewijze voorspellingsnauwkeurigheid ten opzichte van een onbekende 'ground truth', maar eerder in termen van geotechnische plausibiliteit, interne consistentie en samenhang met waargenomen data.


## 2.3 Wat SchemaGAN doet

SchemaGAN is een conditioneel Generative Adversarial Network dat is ontwikkeld bij Deltares en TU Delft voor het genereren van tweedimensionale ondergrondschematisaties op basis van beperkte CPT-data. Het model bouwt voort op het methodologische raamwerk beschreven in Campos Montero et al. (2025a) en is getraind met behulp van een grote synthetische database van geotechnische dwarsdoorsneden die zijn gegenereerd met het GeoSyn-raamwerk (Campos Montero et al., 2025b).

### 2.3.1 Wat het model leert

Het model is getraind op een grote synthetische database van 24.000 dwarsdoorsneden (Campos Montero, 2024) die een breed scala aan stratigrafische configuraties vertegenwoordigen, typisch voor delta-omgevingen (zie Figuur 1). De trainingsdata zijn gegenereerd onder een aantal expliciete aannames:

- De ondergrond wordt weergegeven als een gelaagd systeem.
- Lagen verschillen in dikte en geometrie, inclusief golvende grenzen, insnijdingen, lenzen en opgevulde geulen.
- Een vlak maaiveld wordt aangenomen als bovengrens.
- Binnen elke laag zijn de materialen ruimtelijk variabel, weergegeven met willekeurige velden met gedefinieerde correlatiestructuren.



Figuur 1 Voorbeelden van synthetische schematisaties die worden gebruikt bij de training van SchemaGAN, met verschillende niveaus van stratigrafische complexiteit



### 2.3.3 Aannames en beperkingen

De toepassing van SchemaGAN is onderhevig aan verschillende aannames en beperkingen. Het model leert ondergrondpatronen uit synthetische trainingsdata en weerspiegelt daarom de aannames die in die database zijn ingebouwd. Deze omvatten gelaagde ondergrondstructuren, lateraal continue kenmerken en een vlak maaiveld. De kwaliteit en bruikbaarheid van de gegenereerde schematisatie hangen af van de beschikbaarheid, spreiding en representativiteit van de ingevoerde CPT-data.

SchemaGAN leidt geen geologische processen af en genereert geen structuren buiten het bereik van patronen die in de trainingsdata zijn vertegenwoordigd. De resultaten moeten daarom worden geïnterpreteerd als plausibele ondergrondschematisaties en niet als definitieve representaties van de werkelijke ondergrond. Ingenieursbeoordeling blijft essentieel bij het gebruik van de resultaten voor ontwerp- of beoordelingsdoeleinden.

## 2.4 Wat we in dit project willen bereiken

Het doel van het toepassen van SchemaGAN in dit project is niet om conventionele methoden voor ondergrondmodellering te vervangen, maar om te onderzoeken hoe AI-gebaseerde generatieve modellen de ondergrondschematisatie voor waterkeringen kunnen ondersteunen en verbeteren.

Specifiek richt dit project zich op:

1. Het integreren van een op conditionele GAN gebaseerde ondergrondschematisatie-aanpak in de bestaande workflow van de Data Fusion Toolbox.
2. Het demonstreren van de toepassing van SchemaGAN op een echte waterkering-casestudy op basis van een tweetal profielen.
3. Het beoordelen van hoe het toevoegen van nieuwe of aanvullende ondergronddata de resulterende schematisatie beïnvloedt en epistemische onzekerheid vermindert.
4. Het identificeren van locaties langs de waterkering waar aanvullend terreinonderzoek het meest waardevol zou zijn, ondersteund door onzekerheidsindicatoren die door het model worden afgeleid.

## 3 AI voor ARK

### 3.1 Case study – Digital Twin ARK

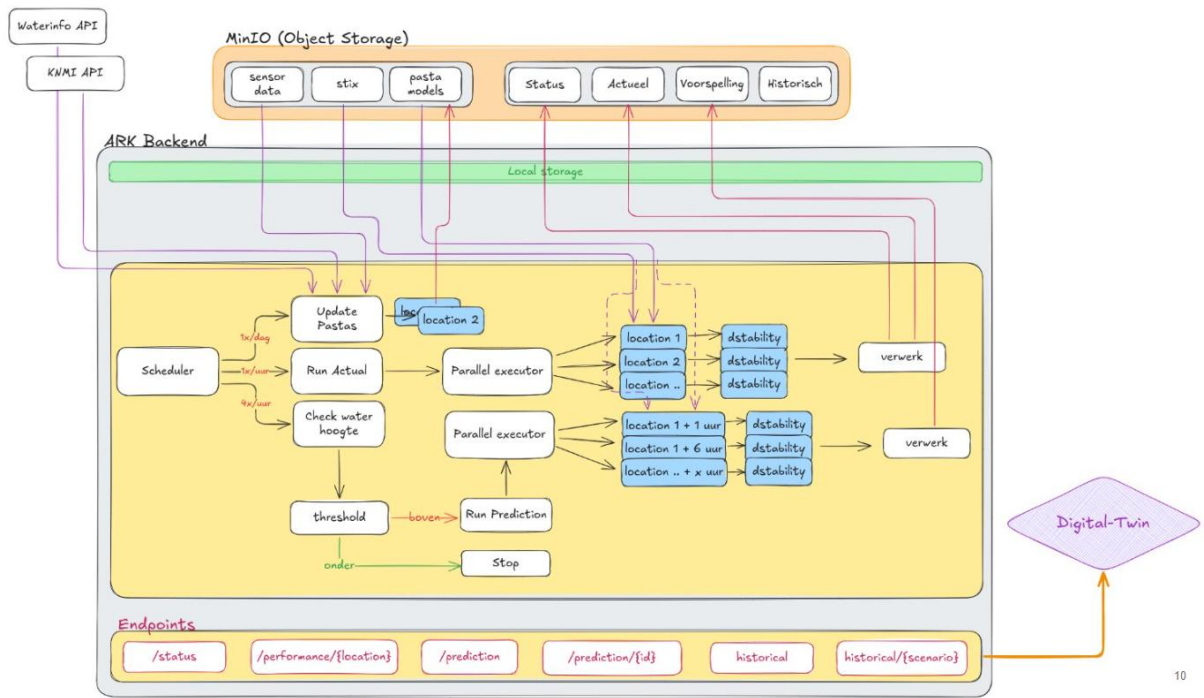
De Digital Twin ARK richt zich op het Betuwepand dat gelegen is tussen de rivieren de Waal en de Nederrijn/Lek en een lengte van circa 12 km heeft.



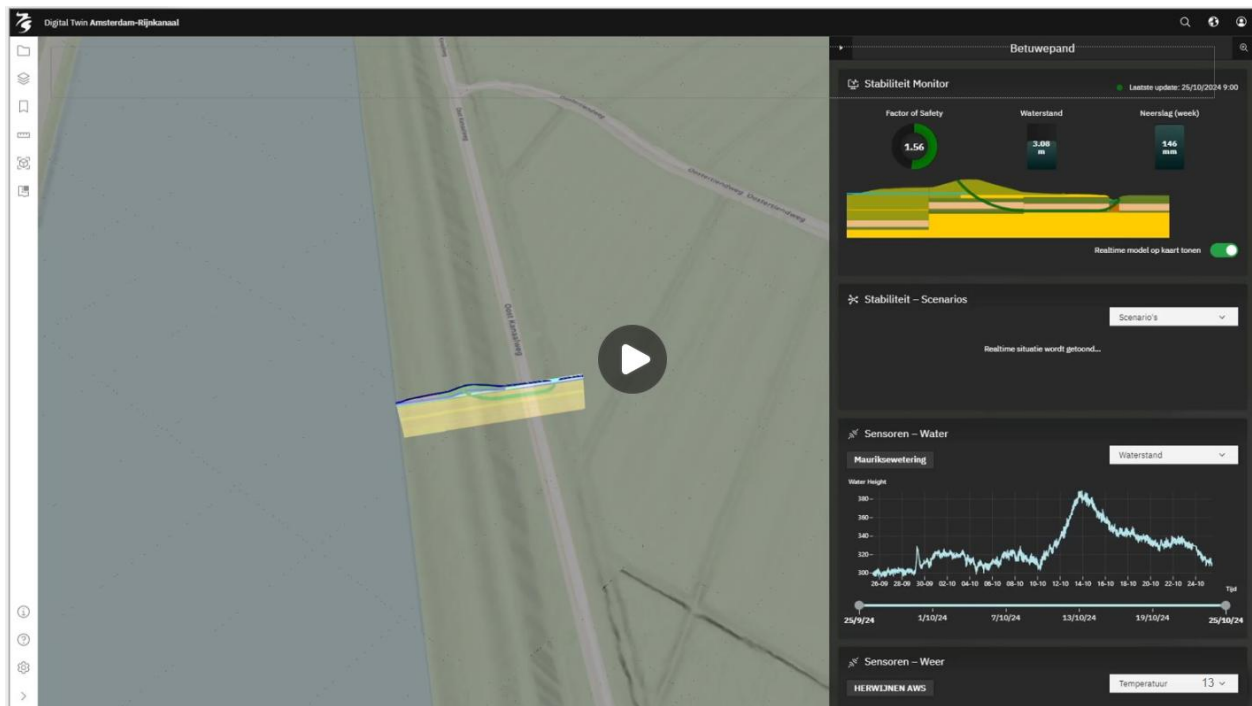
Figuur 4 Ligging van de Digital Twin ARK

In 2024 en 2025 is in het kader van het Corporate Innovation Programma van Rijkswaterstaat voor dit gebied een proof-of-concept van een Digital Twin ontwikkeld om te onderzoeken hoe een Digital Twin het proces van monitoring naar informatie en inzicht over faalmechanismen en de besluitvorming kan ondersteunen. Uitgangspunt is om aan te sluiten bij de Digital Twin-architectuur zoals deze in ontwikkeling is bij Rijkswaterstaat. De Digital Twin voor het Betuwepand richt zich daarbij op de stabiliteit van de kanaaldijk met focus op de volgende aspecten:

- Elke 100 meter beschikbaar hebben van stabiliteitsberekeningen voor de west- en oostkanaaldijk
- Ontwikkeling van een front-viewer voor gebruikersinteractie
- Demonstratie voor 3 situaties:
  - Actuele stabiliteit
  - 24-uur vooruit voorspelling van de stabiliteit (overschrijding waterstand Lek)
  - Scenario's voor stabiliteitsberekeningen



Figuur 5 Schematische architectuur van de Digital Twin ARK



Figuur 6 Screenshot van de user interface met stabiliteitsberekening voor een profiel van het Betuweband

Verdere ontwikkelingen richten zich op:

- Voeden/uitbreiden/updaten met metingen/monitoring/sensing
- Opschalen naar strekkingen en uiteindelijk naar gehele ARK
- Verfijnen van relevante aspecten: degradatie door corrosie, ondergrondschematisatie, doorlatendheid kanaalbodem/kwel vanuit kanaal
- Aansluiten op het dagelijks beheer van het ARK

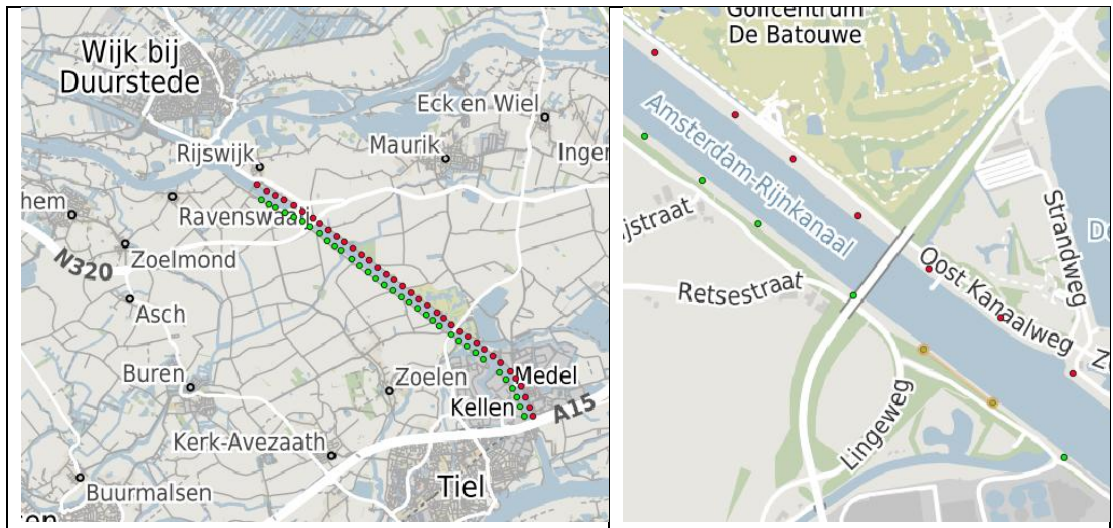
In het voorliggende VOW-project is nagegaan hoe AI een bijdrage aan deze doelstellingen kan leveren. Daarbij is gekozen voor het ontwikkelen van een routine waarmee geautomatiseerd ondergrondschematisaties gemaakt kunnen worden die als input voor de stabiliteitsberekeningen kunnen dienen. Het maken en updaten van ondergrondschematisaties is een tijdrovend proces. Tegelijkertijd wordt de toepasbaarheid van de Digital Twin ARK voor het Betuwepand mede bepaald door de stabiliteitsberekeningen. Het geautomatiseerd updaten van deze berekeningen is dus van grote waarde. In dit hoofdstuk beschrijven we de resultaten van het in hoofdstuk 2 toegelichte AI-model voor ondergrondschematisaties voor de casus Digital Twin ARK Betuwepand.

## 3.2 Toepassing van SchemaGAN in Digital Twin ARK

Deze sectie presenteert de toepassing van SchemaGAN op de ARK-casestudy bij het Betuwepand. De focus ligt op de resulterende ondergrondschematisaties, bijbehorende onzekerheidsindicatoren en de toegevoegde waarde ten opzichte van de huidige praktijk. Methodologische details worden tot een minimum beperkt en, waar relevant, opgenomen in de bijlagen.

### 3.2.1 Betuwepand-casestudy

Ondergrondinformatie langs dit traject is beperkt tot discrete in-situ onderzoeken, voornamelijk sonderingen (CPT's) en boringen, met overwegend een regelmatige afstand van 250 m langs het tracé.



*Figuur 7 Locatie van het Betuwepand langs het Amsterdam-Rijnkanaal. Rode (oost) en groene (west) cirkels geven de beschikbare sonderingen (CPT's) langs het kanaal weer, met een overwegend regelmatige afstand van 250 m.*

Het onderzochte gebied in het Betuwepand strekt zich uit over ongeveer 8.800 m en is verdeeld in twee dijken: oost (E) en west (W). De oostelijke dijk (groene cirkels) bevat 34 sonderingen (CPT's) en de westelijke dijk (rode cirkels) 36 sonderingen. Op exact dezelfde locaties als de CPT's zijn ondiepe boringen beschikbaar, maar deze worden in dit onderzoek niet expliciet gebruikt vanwege de aard van het SchemaGAN-model. De CPT-metingen bereiken een maximale diepte van circa 13 m NAP.

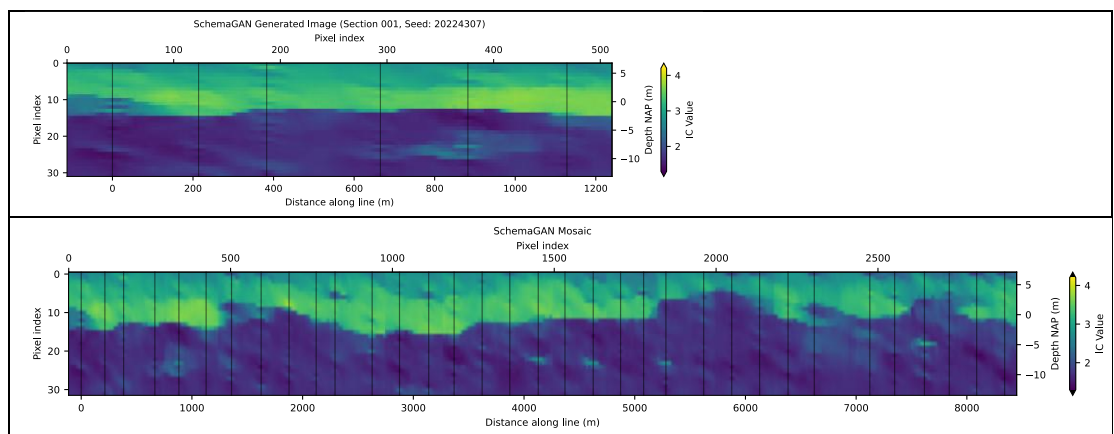
De ondergrondschematisatie wordt uitgevoerd langs de lengterichting van het kanaal, waar aanzienlijke laterale variabiliteit langs het tracé wordt verwacht. De aanwezige materialen worden gekarakteriseerd door gelaagde afzettingen van organische klei, klei boven een zandlaag met lateraal variërende diktes, zoals beschreven in Arcadis (2011a).

### 3.2.2 Baseline SchemaGAN-schematisatie

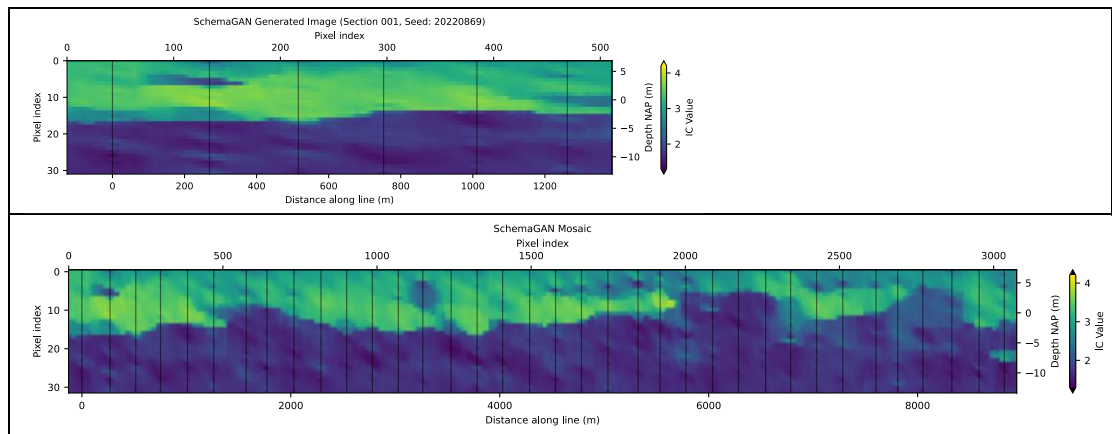
De baseline-ondergrondschematisatie is gegenereerd met het ongemodificeerde SchemaGAN-model. Het model produceert tweedimensionale schematisaties met een resolutie van 32 pixels in de diepte en 512 pixels langs de lengterichting, uitgedrukt in termen van de Soil Behaviour Type-index (Ic).

Het circa 8800 meter lange Betuwepand-tracé is onderverdeeld in negen overlappende longitudinale segmenten, elk met ongeveer zes CPT-locaties (met twee CPT overlap). SchemaGAN is onafhankelijk toegepast op elk segment, waarna de afzonderlijke resultaten zijn samengevoegd tot een doorlopend longitudinaal mozaïek voor elke dijk. In deze fase zijn geen resolutieverbeteringen, onzekerheidsinschattingen of nabewerkingsstappen toegepast. De resulterende baseline-schematisaties tonen een duidelijk stratigrafisch contrast, met overwegend zandige materialen op diepte en meer kleiige materialen richting het maaiveld. Laaggrenzen vertonen lateraal variërende geometrieën, waaronder lenzen en insnijdingen, terwijl interne variabiliteit binnen afzonderlijke lagen behouden blijft door ruimtelijke variaties in Ic-waarden.

Figuur 8 en Figuur 9 tonen de baseline SchemaGAN-schematisaties voor respectievelijk de westelijke en oostelijke dijk. Voor elke dijk wordt een gedetailleerde weergave van het eerste longitudinale segment boven het volledige longitudinale mozaïek weergegeven. Deze resultaten vormen de referentie waarmee de modelverbeteringen en onzekerheidsanalyses in de volgende secties worden geëvalueerd.



Figuur 8 Gedetailleerde weergave van het eerste segment van 1.200 m van de westelijke Betuwepand-schematisatie (boven) en het volledige mozaïek van de 8.800 m lange strekking (onder).



Figuur 9 Gedetailleerde weergave van het eerste segment van 1.200 m van de oostelijke Betuwepand-schematisatie (boven) en het volledige mozaïek van de 8.800 m lange strekking (onder).

### 3.2.3 Verbeteringen geïntroduceerd in dit project

Er zijn verschillende verbeteringen aangebracht in de baseline SchemaGAN-workflow om de interpretatie van ondergrondschematisaties te verbeteren en onzekerheid expliciet te kwantificeren. De focus lag op verbeteringen die de technische interpretatie en besluitvorming ondersteunen. Technische implementatiedetails zijn opgenomen in de bijlagen.

#### *Verbeterde ruimtelijke resolutie*

De baseline SchemaGAN comprimeert CPT-informatie tot een beperkte verticale resolutie van 32 pixels. Om overmatige middeling van de oorspronkelijke CPT-metingen te voorkomen en complexe stratigrafische kenmerken beter vast te leggen, is een verhoogde effectieve verticale resolutie geïntroduceerd. Dit werd bereikt door het verticale domein op te delen in meerdere secties en SchemaGAN afzonderlijk toe te passen, en de resultaten vervolgens te combineren.

Deze aanpak resulteerde in scherper gedefinieerde laaggrenzen en een verbeterde weergave van complexe geometrieën zoals lenzen en insnijdingen, terwijl consistentie met de CPT-data behouden bleef. Horizontale overlap tussen secties is geoptimaliseerd om kunstmatige discontinuïteiten te vermijden. Details van de resolutiestrategie en gevoeligheidstests zijn opgenomen in Bijlage A.

#### *Modelonzekerheid inschatten*

Om het vertrouwen in de modelvoorspellingen te beoordelen, is een onzekerheidsanalyse uitgevoerd met behulp van een Monte Carlo-“dropout”-strategie. Dezelfde ondergrondsectie is meerdere keren gegenereerd met stochastische “dropout” tijdens inferentie, wat resulteerde in een ensemble van schematisaties.

De resulterende variabiliteit weerspiegelt modelonzekerheid en geeft locaties aan waar voorspellingen gevoelig zijn voor modelaannames en dataconditioning. Deze onzekerheid vertegenwoordigt geen natuurlijke bodemvariabiliteit, maar geeft een indicatie van het vertrouwen in de gegenereerde schematisatie. De Monte Carlo-onzekerheidsmethodologie wordt beschreven in Bijlage B.

#### *Ruimtelijke epistemische onzekerheid en validatie*

Om de onzekerheid die voortkomt uit een beperkte bemonstering te beoordelen, is een leave-outstrategie toegepast. CPT's zijn systematisch verwijderd op willekeurige locaties, ondergrondschematisaties zijn opnieuw gegenereerd en de resultaten zijn vergeleken met de schematisatie op basis van de volledige dataset. Deze procedure is meerdere keren herhaald om gebieden te identificeren waar de schematisatie gevoelig is voor ontbrekende data.

Locaties met sterke gevoeligheid komen overeen met gebieden met complexere ondergrondgeometrieën en een hogere afhankelijkheid van lokale metingen. Omgekeerd geven gebieden met lage gevoeligheid robuuste interpretaties aan, waar aanvullende data weinig impact zouden hebben. Dit biedt een directe, ruimtelijk expliciete maat voor epistemische onzekerheid en benadrukt locaties met hoge onzekerheid.

Dezelfde leave-outstrategie is gebruikt voor modelvalidatie door gegenereerde waarden te vergelijken met de achtergehouden CPT-data met behulp van standaard foutmaten (meas absolute error (MAE) en mean square error (MSE)). Dit geeft een kwantitatieve indicatie van de modelprestatie op niet-gezien locaties. De leave-out onzekerheids- en validatieprocedures worden beschreven in Bijlage C.

#### *Beeldverbeteringsmethoden*


Er zijn verschillende post-processingmethoden onderzocht om de visuele scherpheid van laaggrenzen in de SchemaGAN-schematisaties te verbeteren. De workflow werd toegepast op de GAN-uitvoerafbeeldingen via een speciale module die meerdere methoden ondersteunt, waaronder guided filtering, unsharp masking, Laplacianse beeldverbetering en dense conditional random fields. Deze methoden zijn uniform toegepast op alle gegenereerde secties, en de verbeterde uitvoer is gevisualiseerd met dezelfde ruimtelijke referentie, diepteschaal en CPT-overlay als de oorspronkelijke schematisaties.

Er werd geen consistente verbetering in geotechnische interpreteerbaarheid waargenomen, omdat de prestaties van de verbeteringsmethoden gevoelig bleken voor parameterkeuzes. Bovendien zijn slechts beperkte experimenten uitgevoerd, aangezien de focus van het project lag op het verbeteren van het onderliggende generatieve model in plaats van op post-processing.

Op basis van deze bevindingen zijn methoden voor beeldverbetering niet opgenomen in de definitieve workflow. Verdere onderzoeken kunnen in de toekomst zinvol zijn om de toepasbaarheid te beoordelen in combinatie met alternatieve modelarchitecturen of uitgebreidere kalibratie.

### **3.2.4 Resulterende ondergrondschematisaties**


Figuur 10 en Figuur 11 tonen de nieuwe SchemaGAN-schematisaties en onzekerheid na implementatie van de verbeteringen die in sectie 3.2.3 zijn beschreven.



*Figuur 10 Verbeterde SchemaGAN-schematisatie van de westelijke Betuwepand-dijk. Boven: gedetailleerde weergave van het meest linkse segment van het mozaïek met drie verticaal overlappende secties en verhoogde resolutie. Onder: verbeterde schematisatie van het ~8.800 m lange longitudinale mozaïek van de westelijke dijk.*

Er is een duidelijke verbetering in de resolutie en detaillering van de schematisaties dankzij de grotere hoeveelheid CPT-data die met de verbeterde methode door het SchemaGAN-model kan worden verwerkt. Complexe structuren zoals insnijdingen en lenzen zijn scherper en beter gedefinieerd, wat de technische interpretatie en afbakening van kritieke zones ondersteunt.

De verbeterde schematisaties behouden de algemene stratigrafische trends die in de baseline-resultaten zijn waargenomen, terwijl ze meer ruimtelijke details en continuïteit langs het tracé bieden. Interne variabiliteit binnen afzonderlijke lagen blijft behouden, wat de interpretatie van zowel dominante gelaagdheid, grenzen als lokale heterogeniteit ondersteunt. Deze resultaten vormen de basis voor de onzekerheidsanalyse en vergelijking met de huidige praktijk, zoals gepresenteerd in de volgende secties.



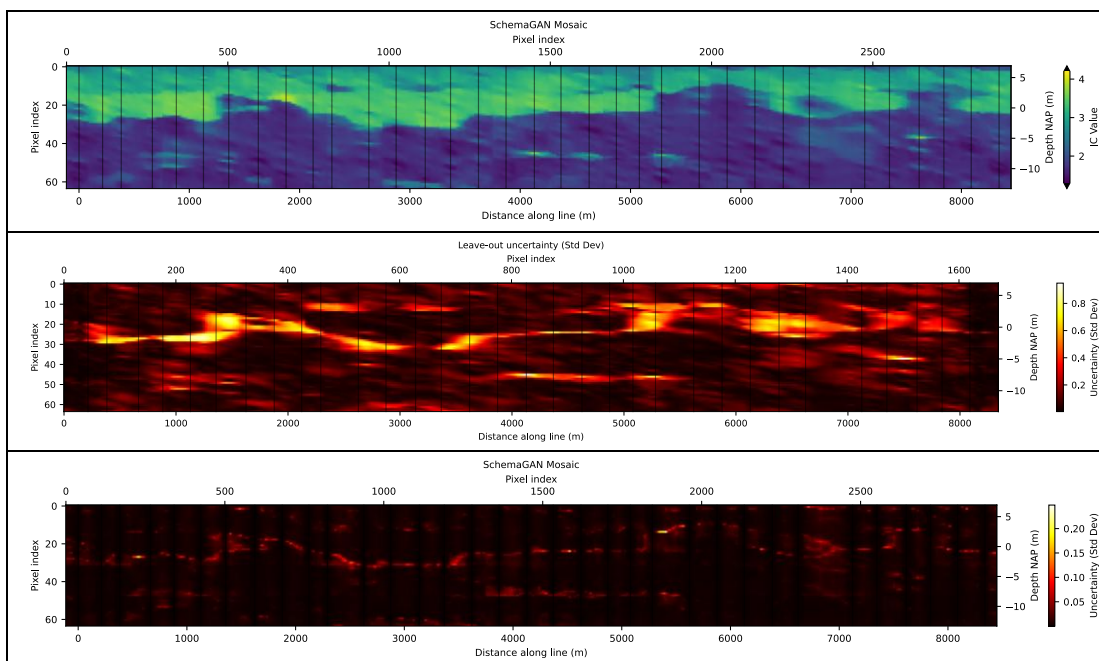
*Figuur 11 Verbeterde SchemaGAN-schematisatie van de oostelijke Betuwepand-dijk. Boven: gedetailleerde weergave van het meest linkse segment van het mozaïek met drie verticaal overlappende secties en verhoogde resolutie. Onder: verbeterde schematisatie van het ~8.800 m lange longitudinale mozaïek van de oostelijke dijk.*

### 3.2.5 Onzekerheid en aandachtspunten

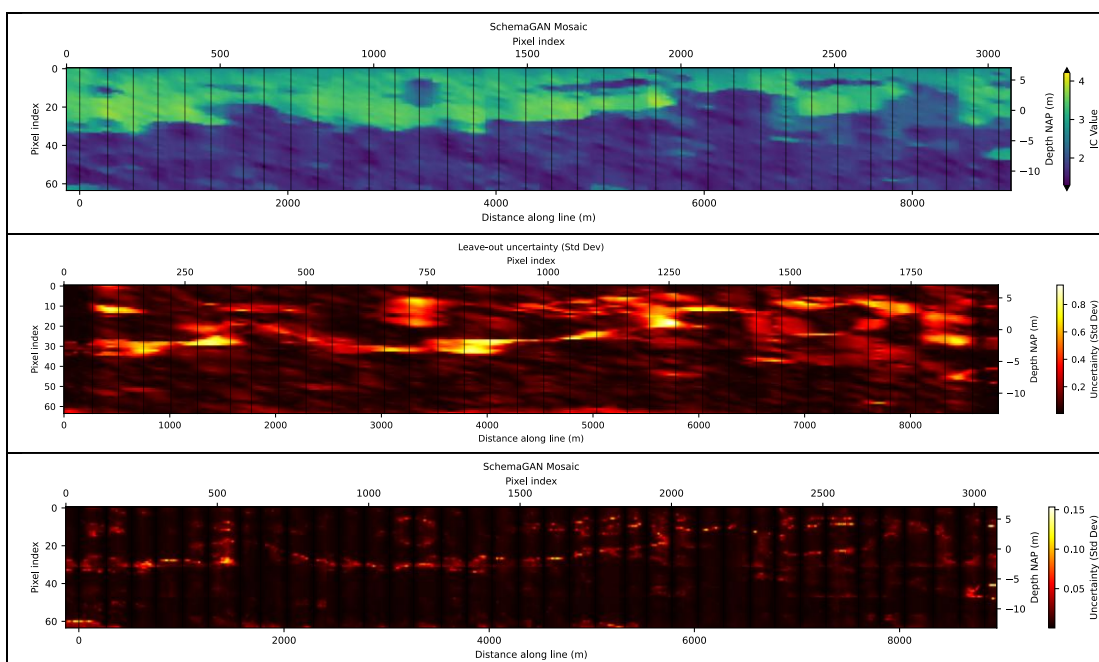
Onzekerheid is beoordeeld om te identificeren waar data cruciaal is voor de ondergrondschematisatie. De focus ligt op ruimtelijke (epistemische) onzekerheid, die direct de afhankelijkheid van de schematisatie van lokale CPT-informatie weerspiegelt en helpt bij het aanwijzen van gebieden die extra aandacht vereisen.

De resultaten in Figuur 10 en Figuur 11 tonen een duidelijke relatie met de complexiteit van de ondergrond langs het tracé. Secties met een lateraal uniforme stratigrafie vertonen lage relatieve onzekerheid, wat wijst op een robuuste interpretatie van de ondergrond. Daarentegen worden hogere relatieve onzekerheidswaarden waargenomen in zones met complexe geometrieën, zoals lenzen, insnijdingen en onregelmatige laaggrenzen, waar de schematisatie sterker afhankelijk is van lokale CPT-data.

Modelonzekerheid, afgeleid van Monte Carlo-dropout (Figuur 12 en Figuur 13), is aanzienlijk geringer, wat aangeeft dat de SchemaGAN-voorspellingen stabiel zijn over opeenvolgende modelrealisaties. Ondanks de lagere waarden volgt de ruimtelijke verdeling van modelonzekerheid vergelijkbare trends, met verhoogde onzekerheid geconcentreerd nabij laaggrenzen.



Figuur 12 Onzekerheden van de SchemaGAN schematisatie voor het westelijke Betuwepand (boven). Midden: ruimtelijke onzekerheid op basis van de leave-out strategie. Onder: modelonzekerheid uit de Monte Carlo-dropoutanalyse.



Figuur 13. Onzekerheden van de SchemaGAN schematisatie voor het oostelijk Betuwepand (boven). Midden: ruimtelijke onzekerheid op basis van de leave-out strategie. Onder: modelonzekerheid uit de Monte Carlo-dropoutanalyse.

De locaties met verhoogde ruimtelijke onzekerheid definiëren duidelijke aandachtspunten langs de waterkering. In deze zones zijn de ondergrondcondities complexer en zou aanvullend terreinonderzoek naar verwachting het grootste voordeel opleveren voor het verbeteren van de schematisatie.

### 3.2.6 Kwalitatieve vergelijking met de huidige praktijk

De SchemaGAN-resultaten zijn kwalitatief vergeleken met de ondergrondinterpretaties die momenteel in de praktijk worden gebruikt voor het Betuwepand, zoals aangeleverd door Rijkswaterstaat en opgesteld door Arcadis. Deze vergelijking moet met voorzichtigheid worden geïnterpreteerd, aangezien de twee schematisaties zijn afgeleid op basis van fundamenteel verschillende databronnen, classificatiesystemen en interpolatiemethoden. Een directe één-op-één vergelijking is daarom niet mogelijk.


De Arcadis-schematisaties lijken gebaseerd op een combinatie van CPT-data, boorbeschrijvingen en lineaire interpolatie tussen boor- en sondeerlokaties. Er worden vijf materiaaltypen onderscheiden: kleiig-zandig, kleiig-siltig, kleiig-organisch, veenachtig-kleiig en zand. De SchemaGAN-schematisaties zijn gebaseerd op CPT-afgeleide Soil Behaviour Type-index (Ic)-waarden en volgen het Robertson-classificatiekader. Om een kwalitatieve vergelijking mogelijk te maken, is de continue Ic-uitvoer gegroepeerd in vijf materiaalcategorieën (Robertson & Cabal, 2022), die grofweg overeenkomen met organisch materiaal, klei, siltmengsels, zandmengsels en zand (Figuur 14 en Figuur 15). Een specifieke kleurenschaal is toegepast om deze klassen visueel af te stemmen op het aantal materiaaltypen dat in de Arcadis-schematisaties wordt gebruikt. Ondanks deze harmonisatie blijven de materiaaldefinities conceptueel verschillend en moeten ze worden geïnterpreteerd als benaderende equivalenten in plaats van identieke klassen.

Een verder fundamenteel verschil ligt in de weergave van laaggrenzen. De SchemaGAN-schematisaties genereren organisch variërende laaggeometrieën die patronen weerspiegelen die zijn geleerd uit trainingsdata en CPT-conditionering, wat resulteert in niet-lineaire en ruimtelijk variabele grenzen. De Arcadis-schematisaties daarentegen gebruiken lineaire grenzen, die eenvoudiger te interpreteren zijn en direct toepasbaar in ontwerpsoftware. Beide representaties hebben dus inherente voor- en nadelen.

De volgende vergelijking richt zich op kwalitatieve verschillen in stratigrafische continuïteit, geometrische representatie en consistentie tussen onderzoeksposities, en niet op juistheid of prestaties. Het doel is om te illustreren hoe de AI-gebaseerde aanpak de huidige praktijk aanvult en een alternatief perspectief biedt op ondergrondcomplexiteit langs het tracé.


Figuur 14 toont een kwalitatief goede overeenkomst tussen beide schematisaties, met een oppervlakkige kleilaag die wordt onderliggend door organisch materiaal en zand. Er zijn verschillen zichtbaar in de geïnterpreteerde dikte van de organische laag. In de SchemaGAN-schematisatie wordt de omvang van het organische materiaal consequent bepaald door de CPT-afgeleide Ic-drempel, wat resulteert in een dikkere en lateraal meer continue laag. Daarentegen is de Arcadis-interpretatie lokaal beperkt door een enkele boring, wat leidt tot een dunnere organische laag.

Dit illustreert hoe de SchemaGAN-aanpak een systematische en data-consistente interpretatie van materiaalverdeling biedt, waardoor de afhankelijkheid van geïsoleerde waarnemingen wordt verminderd en onderliggende aannames expliciet worden gemaakt.



Figuur 14 Initiële, meest linkse sectie van de westelijke Betuwepand-dijk met bovenaan de Arcadis-schematisatie en onderaan de SchemaGAN-schematisatie.

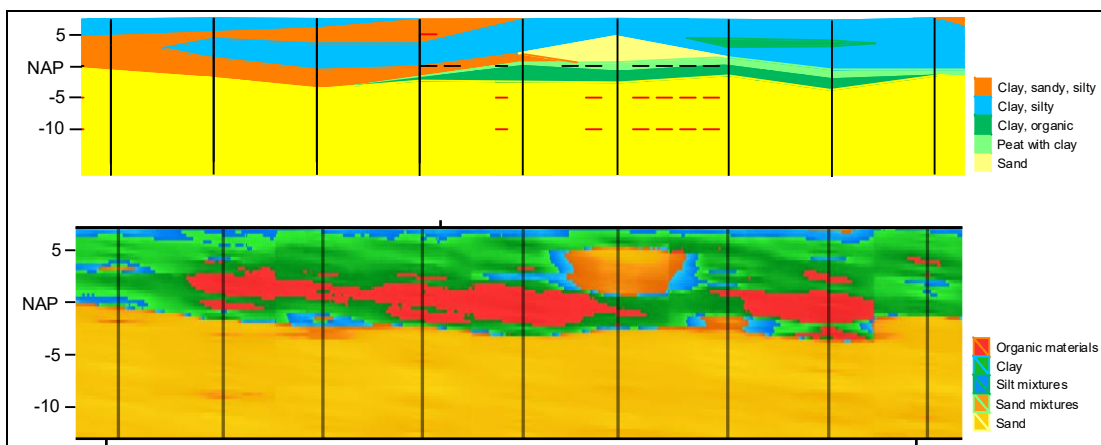
Figuur 15 toont opnieuw een kwalitatief goede overeenkomst tussen beide modellen. Beide dwarsdoorsneden identificeren bij de tweede CPT van links naar rechts een zandlens binnen de kleimaterialen. Opnieuw laten de SchemaGAN-resultaten een dikkere laag organisch materiaal zien, die wordt bepaald door de Ic-waardelimiet.



Figuur 15 Initiële, meest linkse sectie van de oostelijke Betuwepand-dijk met bovenaan de Arcadis-schematisatie en onderaan de SchemaGAN-schematisatie.


In Figuur 16 is de laaggeometrie inherent complexer. Beide schematisaties identificeren de zandlens in het midden van de figuur, maar SchemaGAN genereert een organische vorm, bijna als een kleine begraven geul. Arcadis daarentegen, met lineaire interpolatie, modelleert het zand als een trapezium met zeer smalle randen. Dit soort keuzes in de schematisatie kan een verschil maken bij het bepalen van de dikte van het zand dat op deze locatie moet worden gemodelleerd. Het resulterende verschil in geïnterpreteerde zanddikte kan invloed hebben op hoe dit kenmerk wordt weergegeven in vervolgmодellering, wat de impact van interpolatieaannames op technische analyses benadrukt.

Beide schematisaties leggen ook organisch materiaal op een verschillende manier vast. Arcadis modelleert een doorlopende dikke laag, terwijl SchemaGAN ervoor kiest om het organische materiaal op te splitsen in drie afzonderlijke secties met een grotere laagdikte.




*Figuur 16 Middensectie van de oostelijke Betuwepand-dijk, beginnend bij circa 2.000 m aan de linkerkant, met bovenaan de Arcadis-schematisatie en onderaan de SchemaGAN-schematisatie.*

In Figuur 17 en Figuur 18 worden de volledige SchemaGAN-resultaten gepresenteerd voor de complete westelijke en oostelijke lengtesecties. Dit zijn dezelfde figuren als 7 en 8, maar met lithologische eenheden op basis van IC-waarden om de uitkomsten beter te kunnen vergelijken met de profielen van Arcadis.



Figuur 17 Verbeterde SchemaGAN-schematisatie: ~8.800 m longitudinaal profiel van de westelijke dijk in het Betuwepand.



Figuur 18 Verbeterde SchemaGAN-schematisatie: ~ 8.800 m longitudinaal profiel van de oostelijke dijk in het Betuwepand.

	Material	Color	Ic-values
	Organic materials	Red	> 3.40
	Clay	Green	2.95 – 3.40
	Silt mixtures	Blue	2.60 – 2.95
	Sand mixtures	Yellow	2.05 – 2.60
	Sand	Light Yellow	< 2.05

## 4 Discussie en Conclusies

De in dit rapport beschreven AI-toepassing past binnen de ontwikkeling van Digital Twins voor waterveiligheid. De functionaliteit is weliswaar sterk toegesneden op het schematiseren en updaten van ondergrondmodellen voor geotechnische berekeningen maar illustreert ook de inzet van AI kan leiden tot zeer snelle modellen en workflows.

De in deze studie nader toegepaste en uitgewerkte SchemaGAN produceert ondergrondse schematisaties die consistent zijn met bestaande technische interpretaties. De gegenereerde dwarsdoorsneden voor het Betuwepand sluiten goed aan bij de huidige praktijk op basis van sonderingen (CPT's), boringen en interpolatie, terwijl het interpretatieproces transparanter en reproduceerbaar wordt gemaakt.

Belangrijkste praktische voordeel: snelheid en schaalbaarheid. SchemaGAN maakt snelle generatie van longitudinale schematisaties over meerdere kilometers mogelijk, waardoor het geschikt is voor eerste beoordelingen van lange waterkeringtrajecten, waar handmatige interpretatie veel tijd en inspanning zou vergen.

Onzekerheid wordt expliciet en ruimtelijk continu weergegeven. De onzekerheidskaarten tonen waar resultaten gevoelig zijn voor datadichtheid en markeren direct gebieden die extra aandacht vereisen.

Resultaten tonen geotechnisch betekenisvolle onzekerheidspatronen. Hogere onzekerheid hangt consequent samen met complexe ondergrondgeometrieën, terwijl uniforme stratigrafie stabiele resultaten oplevert, wat het vertrouwen in de interpretatie vergroot.

### *Conclusies*

- AI-gebaseerde ondergrondschematisatie is een haalbaar hulpmiddel voor geotechnische beoordeling van waterkeringen, vooral in vroege stadia. SchemaGAN kan consistente, realistische ondergrondschematisaties genereren over lange trajecten en biedt een solide basis voor initiële evaluatie en screening.
- De belangrijkste meerwaarde is de expliciete identificatie van onzekerheid en aandachtsgebieden. Door te tonen waar interpretatie sterk afhankelijk is van lokale data, ondersteunt SchemaGAN gerichte onderzoeksplanning en beter onderbouwd technisch oordeel.
- De aanpak ondersteunt betere beslissingen, niet alleen sneller modelleren. Het vermogen om kritieke zones snel te identificeren en onzekerheid te kwantificeren kan invloed hebben op hoe ondergrondmodellen worden opgebouwd en gebruikt in vervolganalyses, zoals stabiliteitsbeoordelingen.

Volgende stappen in kader van Verkennend Onderzoek Waterveiligheid:

- Het AI-landschap – er blijft een behoefte aan een regelmatige update van de ontwikkelingen en mogelijkheden van AI. Deze ontwikkelingen gaan erg snel en er doen zich voortdurend nieuwe mogelijkheden voor. Er is behoefte aan een verdere uitwerking van een overzicht van toepassingen van AI voor waterkeringen, bijvoorbeeld zoals in opzet de UNESCO-publicatie 'Applications of AI for water

management' die een goed overzicht geeft van de belangrijkste AI-concepten en hun toepassing in water beheer.

- Inpassing – er is een sterke behoefte en gevoelde noodzaak om goed vast te stellen op welke wijze AI ingepast kan worden in de praktijk van beoordelen – ontwerpen – beheren van waterkeringen. Deze keten van activiteiten is sterk genormeerd en voorzien van protocollen. Door de nieuwe wijze waarop AI informatie genereert bestaat er behoefte om vast te stellen wat er nodig is om AI een plek te geven in de bestaande praktijk en om adoptie mogelijk te maken. Een belangrijk aspect daarbij is ook hoe de uitlegbaarheid en validatie van AI-algoritmes geborgd kan worden.
- Infrastructuur – data is de grondstof voor AI en duurzame data beschikbaarheid is een belangrijke voorwaarde voor het kunnen ontwikkelen van nieuwe toepassingen. Hoewel de bestaande data infrastructuur veel kansen biedt is inzicht in bottlenecks in data beschikbaarheid en data kwaliteit van belang om zodoende een voldoende data beschikbaar te hebben voor het trainen van AI-modellen.
- Koppeling van SchemaGAN-uitvoer aan stabiliteitsanalyses om de impact op technische beslissingen te beoordelen.

Verder ontwikkeling SchemaGAN:

- Voor verdere ontwikkeling is introductie van een encoder-decoderframework om SchemaGAN te verbinden met hoge-resolutie CPT-data een mogelijke volgende stap. Dit betreft het ontwikkelen van een encoder-decoderarchitectuur die leert hoe (i) CPT-data wordt gecodeerd naar de compacte conditioneringsrepresentatie die SchemaGAN gebruikt, en (ii) de gegenereerde schematisaties terug te decoderen naar een hoge-resolutie CPT-achtige representatie. Dit maakt het mogelijk om fijnmazige ondergrondkenmerken te benutten en patronen uit echte CPT-data te leren.

## 5 Referenties

Arcadis. (2011a). Legger/beheerregister ARK Betuwepand Oost. Geotechnisch lengteprofiel—Km 62,000—63,000 (No. D03031.001580).

Arcadis. (2011b). Legger/beheerregister ARK Betuwepand West. Geotechnisch lengteprofiel—Km 62,000—63,000 (No. D03031.001580).

Campos Montero, F. A., Zuada Coelho, B., Smyrniou, E., Taormina, R., & Vardon, P. J. (2025a). SchemaGAN: A conditional Generative Adversarial Network for geotechnical subsurface schematisation. *Computers and Geotechnics*, 183, 107177. <https://doi.org/10.1016/j.compgeo.2025.107177>

Campos Montero, F.A., Smyrniou, E., Zuada Coelho, B., Taormina, R., & Vardon, P. J. (2025b). GeoSyn: Synthetic Geotechnical Cross-Sections For Machine Learning Applications. 29th European Young Geotechnical Engineers Conference. Proceedings of the 29th European Young Geotechnical Engineers Conference EYGEC 2025. <https://doi.org/10.32762/eygec.2025.23>

Campos Montero, F.A. (2024). SchemaGAN: Generative Adversarial Network for Geotechnical Schematisation (Version 1). Zenodo. <https://doi.org/10.5281/ZENODO.13143431>

Deltares (2024a) – Verkenning Digital Twin; Memo

Deltares (2024b) – Verkenning Toekomstbeelden Digital Twin, Remote Sensing en AI; Memo

Robertson, P. K., & Cabal, K. (2022). *Guide to Cone Penetration Testing* (7th ed.). Gregg Drilling LLC.

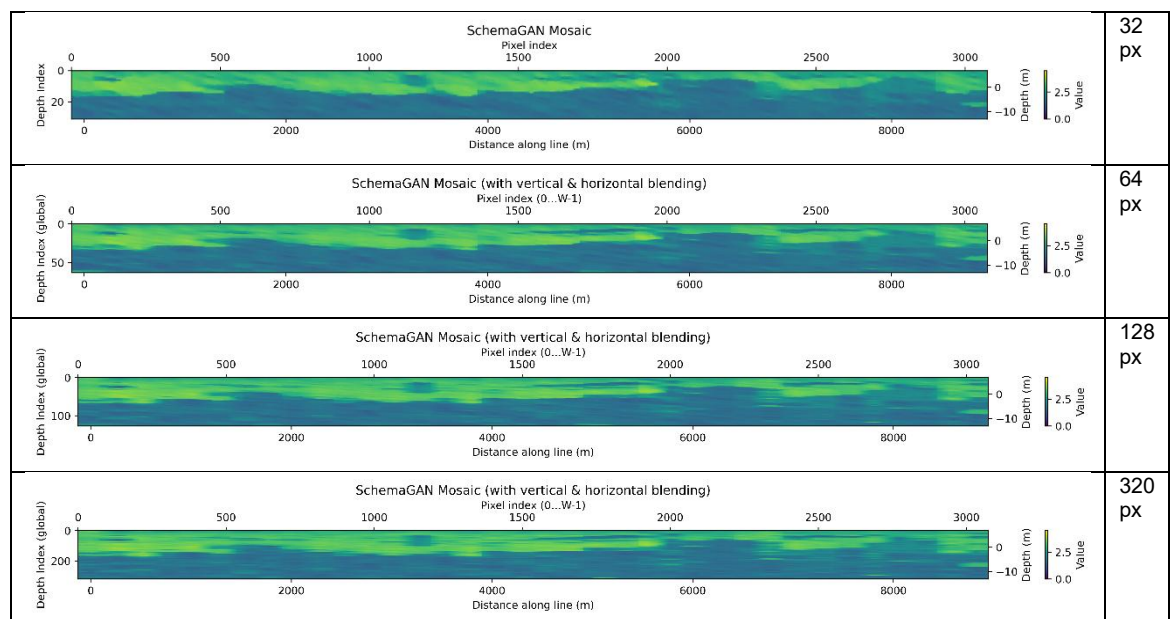
# A Strategie voor verbeterde resolutie en segmentering

Deze bijlage beschrijft de strategie voor resolutieverbetering die is toegepast op de basisworkflow van SchemaGAN. Het doel was om de overmatige verticale middeling van CPT-metingen te verminderen en de weergave van complexe stratigrafische kenmerken te verbeteren.

SchemaGAN werkt in een 32x512-matrix, wat neerkomt op een verticale resolutie van 32 pixels. Om de effectieve resolutie te verhogen, is het verticale domein onderverdeeld in meerdere overlappende secties. SchemaGAN is onafhankelijk toegepast op elke subsectie, waarna de resultaten zijn samengevoegd tot één doorlopende schematisatie. Verschillende verticale resoluties (32, 64, 128 en 320 pixels) en maten van horizontale overlap zijn geëvalueerd.

Het verhogen van de effectieve verticale resolutie resulteerde in scherpere laaggrenzen en een betere definitie van lenzen en insnoeringen. Bij meer dan 64 pixels werd geen significante kwalitatieve verbetering waargenomen. De horizontale overlap is geoptimaliseerd om kunstmatige discontinuïteiten tussen aangrenzende secties te vermijden.

Figuur 19 illustreert met voorbeelden de testen voor resolutieverbetering.



Figuur 19 Representatieve voorbeelden van resolutieverbetering en kwaliteitsverlies bij afname van verticale compressie om meer CPT-data vast te leggen. De resultaten zijn een combinatie van 50% verticale overlap op het verschillende aantal verticale secties dat nodig is om binnen het 32x512-framework te passen.

## B Schatting van modelonzekerheid met behulp van Monte Carlo-dropout

Modelonzekerheid is geschat om de stabiliteit van SchemaGAN-voorspellingen onder stochastische inferentie te beoordelen. Het doel is om locaties te identificeren waar de gegenereerde ondergrondschematisatie gevoelig is voor interne modelvariabiliteit, wat een indicatie geeft van het vertrouwen in de resultaten.

Onzekerheid is gekwantificeerd met behulp van een Monte Carlo-dropoutbenadering. Voor een gegeven invoersectie werd de SchemaGAN-generator meerdere keren geëvalueerd, waarbij de dropoutlagen actief bleven tijdens inferentie. Elke evaluatie leverde een iets andere ondergrondschematisatie op door het stochastische gedrag van dropout, terwijl de invoergegevens ongewijzigd bleven.

Uit de resulterende set voorspellingen werd de gemiddelde voorspelling berekend als het gemiddelde van alle realisaties en gebruikt als de beste schatting van de ondergrondse eigenschap. Modelonzekerheid werd gekwantificeerd als de standaarddeviatie van de voorspellingen op elke ruimtelijke locatie. Typische analyses gebruikten 100 Monte Carlo-samples, wat een balans biedt tussen stabiliteit van de onzekerheidsschatting en rekeninspanning. Geen significante verbeteringen werden waargenomen bij een groter aantal iteraties.

De Monte Carlo-dropoutonzekerheid vertegenwoordigt alleen modelonzekerheid. Het weerspiegelt de gevoeligheid van de voorspellingen voor stochastische variaties in het neurale netwerk en vertegenwoordigt niet natuurlijke bodemvariabiliteit, meetonzekerheid of faalkans. De absolute grootte van de onzekerheidswaarden hangt af van modelschaal en dropoutconfiguratie. Daarom worden de resultaten relatief geïnterpreteerd, met focus op ruimtelijke patronen langs het tracé in plaats van absolute drempelwaarden. Onzekerheidsresultaten zijn gevisualiseerd als ruimtelijke heatmaps die de variabiliteit van voorspellingen binnen de Monte Carlo-ensemble tonen. Waar relevant, zijn de onzekerheidskaarten samen met de overeenkomstige gemiddelde voorspelling gepresenteerd om interpretatie te vergemakkelijken. Visualisaties bevatten ruimtelijke assen in meters langs het tracé en diepte in meters, met optionele markeringen voor CPT-locaties. Naast statische figuren zijn interactieve visualisaties gegenereerd om gedetailleerde inspectie van lokale kenmerken te ondersteunen. Onzekerheidswaarden zijn ook geëxporteerd als tabeldata voor verdere analyse.

Om onzekerheid over het volledige tracé te beoordelen, zijn sectieniveau-onzekerheidskaarten samengevoegd tot doorlopende longitudinale mozaïeken met dezelfde segmentatie-, overlap- en blindingstrategie als toegepast voor de SchemaGAN-schematisaties (Figuur 12). De resulterende mozaïeken bieden een doorlopend ruimtelijk overzicht van modelonzekerheid over de volledige lengte van de waterkering.

## C Ruimtelijke (epistemische) onzekerheid en leave-out-validatie

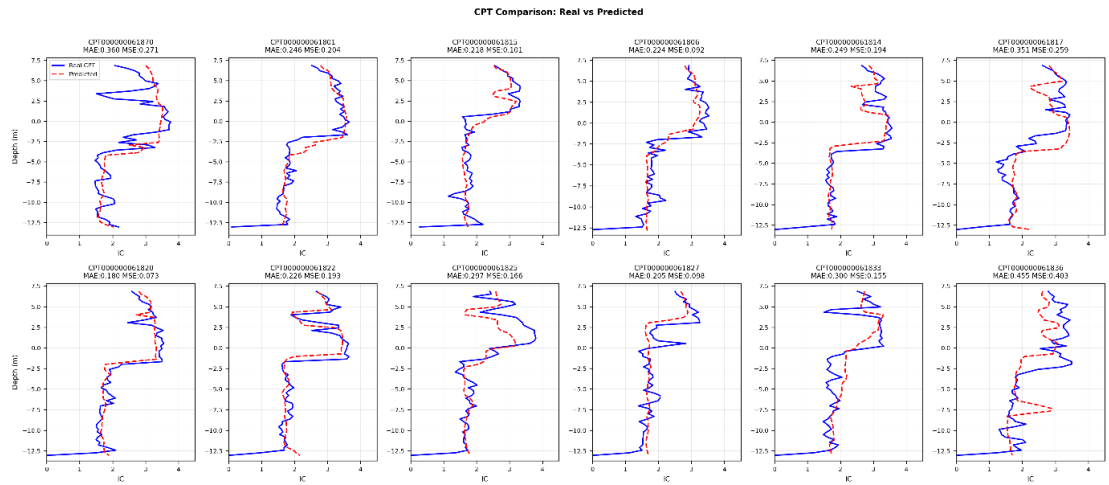
De analyse is gebaseerd op een leave-outstrategie. Vanuit de volledige longitudinale SchemaGAN-schematisatie zijn meerdere alternatieve schematisaties gegenereerd door systematisch subsets van CPT-data weg te laten. Voor elke leave-out-run werd een nieuw longitudinaal mozaïek geproduceerd op basis van de gereduceerde dataset. Dit resulteerde in een reeks validatiemozaïeken, elk een plausibele ondergrondinterpretatie gegeven onvolledige informatie.

Om een consistente vergelijking tussen leave-out-mozaïeken mogelijk te maken, zijn alle validatiemozaïeken herbemonsterd naar een gemeenschappelijke horizontale resolutie. Omdat individuele leave-out-runs mozaïeken met een iets kleinere horizontale omvang opleveren, zijn alle mozaïeken conservatief gedownsamled naar het kleinste gemeenschappelijke aantal kolommen met behulp van gebiedsgewogen averaging. Het oorspronkelijke mozaïek op basis van alle data is met dezelfde procedure gedownsamled om consistentie in de vergelijking te waarborgen.

Ruimtelijke onzekerheid is gekwantificeerd door de variabiliteit over alle leave-out-mozaïeken op elke ruimtelijke locatie te berekenen. Concreet is de standaarddeviatie van de gegenereerde waarden berekend over alle leave-out-runs voor elke pixel in de longitudinale doorsnede. Dit resulteert in een ruimtelijke onzekerheidskaart die locaties markeert waar de schematisatie het meest gevoelig is voor ontbrekende data.

De resulterende onzekerheidswaarden worden relatief geïnterpreteerd. Hogere ruimtelijke onzekerheid duidt op gebieden waar de ondergrondinterpretatie aanzienlijk verandert wanneer CPT-data worden verwijderd, wat een sterke afhankelijkheid van lokale metingen en hogere epistemische onzekerheid weerspiegelt. Lagere ruimtelijke onzekerheid duidt op gebieden waar de schematisatie stabiel blijft ondanks ontbrekende data, wat wijst op een robuuste interpretatie van de dominante stratigrafie.

Hetzelfde leave-outframework vormt de basis voor modelvalidatie. Gegenereerde waarden zijn vergeleken met de achtergehouden CPT-data met behulp van standaard foutmaten zoals mean absolute error (MAE) en mean squared error (MSE). Figuur 20 illustreert een voorbeeld van een validatierun waarin 12 willekeurig geselecteerde CPT's zijn achtergehouden voor vergelijking.



*Figuur 20 Voorbeeld van een specifieke validatierun waarbij 12 willekeurig geselecteerde CPT's zijn achtergehouden om de gegenereerde resultaten te vergelijken met de grondwaarheid op die locaties.*

Voor 600 validatieruns voor de grootste validatieset, werd een gemiddelde MAE van 0,28 met een standaarddeviatie van 0,08 en een gemiddelde MSE van 0,21 met een standaarddeviatie van 0,12 verkregen. Deze waarden zijn consistent met de resultaten gerapporteerd in Campos Montero et al. (2025a). De validatieresultaten ondersteunen de interpretatie van de onzekerheidspatronen, maar zijn niet bedoeld als puntgewijze prestatie maten ten opzichte van een onbekende referentie.

Ruimtelijke onzekerheidskaarten zijn gevisualiseerd als longitudinale heatmaps met diepte en afstand langs het tracé. CPT-locaties zijn toegevoegd om de interpretatie van de relatie tussen onzekerheidspatronen en datadichtheid te ondersteunen. De resulterende onzekerheidsprofielen bieden een ruimtelijk expliciet overzicht van waar aanvullende locatieonderzoeken naar verwachting de grootste meerwaarde zouden bieden voor het verbeteren van de ondergrondschematisatie.

## D Beeldverbeteringsmethoden (niet toegepast)

Er zijn verschillende post-processingmethoden onderzocht om de visuele scherpheid van laaggrenzen in de SchemaGAN-schematisaties te verbeteren. De workflow werd toegepast op de GAN-uitvoerabeelden via een speciale module die meerdere methoden ondersteunt, waaronder guided filtering, unsharp masking, Laplacianse beeldverbetering en dense conditional random fields. Deze methoden zijn uniform toegepast op alle gegenereerde secties, en de verbeterde uitvoer is gevisualiseerd met dezelfde ruimtelijke referentie, diepteschaal en CPT-overlay als de oorspronkelijke schematisaties.

Er werd geen consistente verbetering in geotechnische interpreteerbaarheid waargenomen, omdat de prestaties van de verbeteringsmethoden gevoelig bleken voor parameterkeuzes. Bovendien zijn slechts beperkte experimenten uitgevoerd, aangezien de focus van het project lag op het verbeteren van het onderliggende generatieve model in plaats van op post-processing.

Op basis van deze bevindingen zijn methoden voor beeldverbetering niet opgenomen in de definitieve workflow. Verdere onderzoeken kunnen in de toekomst zinvol zijn om de toepasbaarheid te beoordelen in combinatie met alternatieve modelarchitecturen of uitgebreidere kalibratie.

Deltares is een onafhankelijk kennisinstituut voor toegepast onderzoek op het gebied van water en ondergrond. Wereldwijd werken we aan slimme oplossingen voor mens, milieu en maatschappij.

**Deltares**

[www.deltares.nl](http://www.deltares.nl)