

Memo

Aan

de heer A. Sieben-Rijkswaterstaat Water, Verkeer en Leefomgeving

Datum

23 december 2020

Ons kenmerk

11205234-013-ZWS-0005

Aantal pagina's

1 van 22

Contactpersoon

Arjen Haag

Doorkiesnummer

+31(0)88 335 7480

E-mail

Arjen.Haag@deltares.nl

Onderwerp

Verkenning geautomatiseerde bepaling steilrandlijnen

1 Samenvatting

Op locaties waar de oevers langs de Maas teruggebracht zijn naar een meer natuurlijke staat treedt meer erosie op dan in het verleden. Vanuit Rijkswaterstaat, specifiek het Team Uiterwaardenbeheer, is er de wens om het monitoren van deze eroderende rivieroever meer te automatiseren. Deze memo beschrijft de verkenningstudie die is uitgevoerd naar de mogelijkheden die hiervoor bestaan. Het dient als eerste aanzet en kan gebruikt worden bij het vormgeven van vervolgstudies en projecten.

Voor de uitvoering is gebruik gemaakt van expert-sessies en een voorbeeld-casus. Er is gekeken naar de kennis, ervaring en wensen vanuit zowel Rijkswaterstaat als Deltares. Bij beide organisaties zit veel kennis en ervaring op dit onderwerp. Uit zowel de sessies als de casus kwam naar voren dat er veel mogelijkheden zijn maar dat nog niet duidelijk is wat het beste zou werken. Dit geldt zowel voor de data, als mogelijke methodes, als hoe het uiteindelijk is een toepassing (e.g. applicatie, module) gegoten zou moeten worden. De voorbeeld-casus heeft aangetoond dat het in principe mogelijk moet zijn om automatisch de steilrandlijnen langs de Maas te bepalen, zowel met luchtfoto's als hoge resolutie satellietdata. Echter, de casus was relatief beperkt in scope en kan niet gezien worden als een volledige studie.

Op basis van deze studie komen wij tot een aantal aanbevelingen:

- houdt de in deze studie betrokken personen ook betrokken bij vervolgstappen;
- maak meer gebruik van data die al beschikbaar is (e.g. hoge resolutie satellietbeelden, LiDAR hoogtemetingen), en kijk of databronnen gecombineerd kunnen worden;
- voer een grotere studie uit naar de mogelijkheden, waarbij voortgebouwd kan worden op de informatie uit deze verkenningstudie;
- denk goed na over het einddoel en de eindgebruikers, hierbij kan ook gedacht worden aan een toepassing met meerdere stappen (waarbij een quick-scan als eerste stap kan dienen)

2 Introductie

Deze memo beschrijft de verkenningstudie die uitgevoerd is over het geautomatiseerd bepalen van steilrandlijnen langs de oevers van de Maas. Op dit moment worden deze oevers gemonitord door metingen vanuit het veld, boten en vliegtuigen. De steilrandlijnen specifiek worden handmatig vanuit luchtfoto's ingetekend om zo een beeld te krijgen van de optredende erosie. Dit dient weer als hulpmiddel voor de beheerstaak van de rivieren, oevers en uiterwaarden van Rijkswaterstaat (RWS). Vanuit RWS kwam de vraag of deze handmatige werkzaamheden niet (gedeeltelijk) overgenomen konden worden door automatische processen, om zo het werk te vergemakkelijken en meer te standaardiseren.

Dit werk is uitgevoerd als onderdeel van het KPP-project HV01 2020 - Rivierkundig onderzoek, waarin de dynamiek van water en sediment in de Nederlandse rivieren behandeld wordt. Dit werk sluit direct aan bij een van kaveldoelstellingen van het overkoepelende KPP-project, namelijk “efficiënte en duurzame beheer- of onderhoudsactiviteiten van RWS en zijn partners op het gebied van rivier- en kustbeheer”. Meer indirect heeft het ook een link met de andere kaveldoelstellingen.

Bij het begin van het KPP project in 2020 is afgesproken dat er, wanneer hier nog ruimte voor was, er aan het einde van het jaar een verkenningstudie uitgevoerd zou worden naar het automatiseren van de bepaling van steilrandlijnen. Deze ruimte was er en deze memo is het eindresultaat van de uitgevoerde studie.


2.1 Achtergrond informatie

Langs de Maas zijn op verschillende locaties herinrichtingswerkzaamheden uitgevoerd waarbij de oevers meer natuurlijk zijn gemaakt (zie Figuur 1). Hierbij zijn op sommige locaties de oeverbescherming en -bekleding (gedeeltelijk) weggehaald, om natuurlijke processen zoals afkalving en aanzanding weer meer toe te staan. Hierdoor kan uiteraard meer erosie optreden dan in het verleden het geval was. Hoewel dit juist een van de doelstellingen was van deze herinrichtingswerkzaamheden, kunnen er bij teveel erosie ongewenste problemen optreden.




Figuur 1: Een overzicht van herinrichtingslocaties van Maasoevers (status augustus 2017). Een grotere en interactieve versie van deze kaart, inclusief informatie over alle projecten, is [hier](#) te vinden.

Door Rijkswaterstaat is een software tool ontwikkeld, genaamd 'HTREND', dat ten doel heeft om voorspellingen te doen van (langzame) horizontale uitbreiding van steiloevers. Steiloevers worden gevonden bij zgn. erosiekuilen (onderwateroevers) in de Rijn-Maasmonding en bij eroderende oevers aan de Maas (uiterwaardeoevers). Een schematische weergave van een dwarsdoorsnede van zo'n oever en de toepassing van HTREND is te zien in Figuur 2.



Figuur 2: Extrapolatie van horizontale steilranden (uit De Ruiter et al., 2017)



Figuur 3: Ontwikkeling van een vrij eroderende oever in de loop van de tijd. De snelheid is afhankelijk van lokale omstandigheden inclusief de snelheid van de oevererosie (uit Peters, 2005)

De automatisch bepaalde steilrandlijnen moeten ook als input kunnen dienen voor deze tool. Hoewel deze, zoals op bovenstaande figuur te zien is, bedoeld is om zowel horizontale als verticale trends mee te nemen en te voorspellen, kan deze ook met puur horizontale dynamiek werken (Sinnige en Becker, 2019). Een vrij eroderend oever ontwikkelt zich naar verwachting in de loop der tijd van een verschuivende steilrand naar een flauwere brede oeverzone met oeverwal (Figuur 3). Naar verwachting zal de voorspelling met htrend steeds lastiger worden hoe minder hoog en steil de steilrand of oeverwal wordt.

2.2 Uitvoering studie

De in deze memo beschreven studie is uitgevoerd in verschillende fases. Allereerst zijn zgn. expertsessies gehouden om de randvoorwaarden en opties te verkennen. Daarnaast dienden deze sessies ook om meer inzicht te krijgen in wat de verschillende partijen nodig hebben en verwachten. De uitkomsten van deze sessies zijn beschreven in deze memo (zie Hoofdstuk 3) en dienden als input voor de uitwerking van een voorbeeld-casus (zie Hoofdstuk 4). Conclusies die hieruit getrokken kunnen worden komen als laatste aan bod (zie Hoofdstuk 5).

3 Expert-sessies

In overleg met Rijkswaterstaat, IHE Delft en Deltares zijn expert-sessies gepland om meer inzicht te verkrijgen in de achterliggende vraag, relevante processen, theorie, praktijk en andere relevante zaken. Voor deze sessies zijn verschillende gebruikers en experts van de eerder genoemde organisaties uitgenodigd. In verband met de Corona situatie zijn de sessies online uitgevoerd. Bij elke sessie zijn notities bijgehouden die achteraf ook met alle deelnemers gedeeld zijn, om ervoor te zorgen dat de informatie goed weergegeven is. Dit hoofdstuk is een verdere uitwerking van deze notities.

3.1 Achterliggende gedachten

De originele vraag en potentiële gebruiker van een nieuwe tool is het uiterwaardenbeheer. Zij zien graag een nieuwe tool die erosiegevoelige oevers kan detecteren en monitoren, en op bepaalde locaties een diepere analyse (bijv. snelheid en verwachting van erosie) kan uitvoeren. Natuurlijke oevers hebben veel voordelen maar op locaties waar veel erosie optreedt kunnen ook nadelen ontstaan. Hierbij kan bijvoorbeeld gedacht worden aan gebiedsverlies van andere eigenaars dan RWS, hierover zijn al een aantal klachten binnengekomen. Het is daarom belangrijk om goed zicht te hebben op deze erosie en waar nodig op tijd bij te kunnen sturen.

Vanuit beheers-perspectief komen vragen als “welke percelen worden binnen welke termijn aangetast?”. Hier zit natuurlijk een hele keten van processen achter voordat een aannemer daadwerkelijk aangestuurd wordt om actie te ondernemen. Daarnaast moet ook rekening gehouden worden met allerlei andere processen die dit kunnen beïnvloeden (bijv. volle planning bij aannemers). Dit betekent dat je zeker één jaar, maar liefst wel twee jaar, van te voren wilt weten waar een probleem kan gaan optreden, om op tijd actie te kunnen ondernemen.

Rekening houdend met het bovenstaande is de frequentie waarop dit soort informatie nodig zou zijn minimaal één keer per jaar, liefst juist na een periode waarop erosie optreedt (i.e. hoogwater). Uiteraard zou een hogere frequentie mooi zijn, maar meer dan een paar keer per jaar lijkt absoluut niet nodig.

Tenslotte is het nog relevant om te vermelden dat RWS hier een wettelijke taak heeft om te voldoen aan de Rijkswaterstaatswerkenlegger (update legger eind 2021, opdracht loopt bij RHDHV). En dat niet alleen de oevers langs de rivieren, maar zeker ook de oevers langs de nevengeulen in het rivierengebied behoren tot de scope van Team Uiterwaardbeheer (TU).

3.2 Aandachtspunten

Bij zowel de uitvoering van voorbeeld-casus als potentiële vervolgstudies is het belangrijk om over een aantal zaken na te denken. Zo bestaan er voor een aantal locaties al gedetailleerde (x, y, z) metingen en is het goed om deze locatie(s) te gebruiken, om zo inzicht te krijgen in de nauwkeurigheid. Dit raakt meteen een ander belangrijk punt: hoe kan de nauwkeurigheid precies bepaald worden? Deze kan van veel zaken afhangen, waarbij de resolutie (in zowel tijd als ruimte) van de data een grote rol speelt. Het wordt wat dat betreft aangeraden om ook één (of meerdere) stuk(ken) harde, onbeweeglijke oever mee te nemen welke dienst kan doen als referentie (i.e. baseline). Dit kan een goed beeld geven van het effect van resolutie, voordat gekeken wordt naar de nauwkeurigheid bij eroderende oevers.

De focus bij het bepalen van de steilranden, zowel bij de huidige handmatige intekening als bij een meer geautomatiseerde aanpak, ligt op de detectie van de bovenkant (i.e. talud). Dit is ook wat voor de *htrend* tool het belangrijkste is. Bij volledig loodrechte oevers is er uiteraard geen verschil tussen onder- en bovenkant, maar bij oevers met een flauwere helling wel. Dit soort oevers kunnen ook lastiger zijn voor (automatische) detectie, omdat er een minder duidelijke scheiding is tussen land en water, omdat er wellicht stukken afgekalfde grond/graspollen op liggen, en/of schaduwen een groter effect kunnen hebben. Het kan zijn dat er voor verschillende types oever ook verschillende detectie methodes toegepast moeten worden.

Wat betreft het bovenstaande is het goed om na te denken over bestaande kennis van plekken die wellicht als 'hoog risico' ingeschat kunnen worden. Deze komen waarschijnlijk enigszins overeen met de locaties genoemd aan het begin van deze paragraaf. Wanneer er keuzes gemaakt moeten worden met betrekking tot het aantal locaties zou het goed zijn om ook dit soort 'hoge risico' locaties mee te nemen.

Tenslotte is het ook belangrijk om na te denken over het feit dat veranderingen aan oevers niet altijd door (natuurlijke) erosie tot stand komen. Er kunnen ook menselijke ingrepen ten grondslag aan liggen. Oftewel: hoe houdt je erosie en andere processen (e.g. vergravingen, nieuwe nevengeulen) uit elkaar? Waarschijnlijk valt dit uiteindelijk wel mee en zullen zeker locaties waar grote werkzaamheden plaatsvinden goed bekend zijn (en zal dus een potentiële 'false flag' van een tool geen problemen geven), maar het wordt aangeraden om hier bij vervolgstudies en projecten wel rekening mee te houden.

3.3 Data

Er is veel data dat potentie heeft om gebruikt te worden voor de detectie van steilrandlijnen. Hieronder volgt een beknopt overzicht. Een goed overzicht van data die al beschikbaar is bij RWS is te vinden op <https://www.rijkswaterstaat.nl/apps/geoservices/geodata/dmc/>.

1. Actueel Hoogtebestand Nederland (AHN)
2. Luchtfoto's
3. Satellietdata
4. metingen vanuit boten

Wat betreft ruimtelijke resolutie is 1m waarschijnlijk voldoende, alle hier genoemde databronnen voldoen hier aan (of kunnen er aan voldoen). Naast toepassingen van een losse databron kan het zeker ook interessant zijn om een combinatie of koppeling van databronnen toe te passen.

3.3.1 Actueel Hoogtebestand Nederland

Het Actueel Hoogtebestand Nederland (AHN) is een op LiDAR gebaseerde hoogtekaart van Nederland die eens in de zoveel tijd vernieuwd wordt. Deze is van hoge resolutie (0.5m), maar het zou wellicht ook mogelijk zijn om de achterliggende puntwolken data te gebruiken. Deze data heeft x, y en z metingen en door de verschillende vernieuwingen (e.g. versies) ook een tijdscomponent dat het mogelijk maakt om veranderingen op te sporen.

3.3.2 Luchtfoto's

Ook luchtfoto's worden eens in de zoveel tijd opgenomen. Deze zijn, afhankelijk van hun toepassing en project, beschikbaar in verschillende ruimtelijke resoluties. Er bestaan zeer hoge resolutie foto's (tot 2 cm) die specifiek voor een bepaald project ingevlogen worden en normale resolutie foto's (tot 25cm) die voor meer algemene doeleinden ingevlogen worden. Vaak bestaan deze foto's puur uit RGB banden, hoewel het soms ook mogelijk is om een infrarood band toe te laten voegen (zie ook satellietdata). Tijdens één van de sessies werd vermeld dat er jaarlijks nationale luchtfoto's ingevlogen worden, dat dit één keer per jaar in zwart-wit gebeurt (winter) en één keer per jaar in kleur (zomer).

3.3.3 Satellietdata

Satellieten nemen continue metingen van de aarde. Het is goed om een onderscheid te maken tussen standaard open en gratis beschikbare satellietdata en die van commerciële aanbieders. Vaak hebben satellieten naast een RGB signaal ook één, of meerdere, infrarood sensoren. De resolutie in tijd en ruimte hangt af van de satelliet (en aanbieder): open data heeft vaak een lagere ruimtelijke resolutie (tot 10 m) dan commerciële data (tot 50 cm). Het is belangrijk om hierbij op te merken dat de Netherlands Space Office (NSO) van bepaalde commerciële aanbieders data over Nederland en voor Nederlandse gebruikers gratis beschikbaar stelt op hun satellietdataportaal¹ (bijv. Superview, vanaf 2018 tot 50 cm, en Triplesat, tot 80 cm). Dit betekent dat er voor deze studie ook naar deze data gekeken kan worden. Het is echter niet bekend hoe lang dit mogelijk zal blijven (voor zover bekend loopt de huidige overeenkomst tot 2023). Ook goed om te vermelden is dat er wel bepaalde licenties op deze data zitten, maar voor het gebruik dat wij voor ogen hebben zou dit geen probleem moeten zijn.

3.3.4 Bootmetingen

Vanuit boten worden ook al specifieke metingen gedaan voor RWS. Hier vallen met namen metingen in het 'natte domein' onder, maar er worden af en toe ook metingen van de oevers genomen. Bij dit soort metingen kan gedacht worden aan multi-beam, sonar en LiDAR. Als concreet voorbeeld wordt er vanaf een boot al meerdere keren paar jaar data ingewonnen langs de IJssel. Er is contact met aannemer die dit doet, en hoewel het nu inderdaad gericht is op onderwater-metingen, zou het volgens deze aannemer makkelijk moeten zijn om daar opnameapparatuur specifiek voor de oever(erosie) bij op te nemen.

3.4 Doel studie en vervolgstappen

Het doel van de huidige verkenningstudie is inzicht verkrijgen in wat geautomatiseerd kan worden met betrekking tot de detectie van steilrandlijnen uit luchtfoto's en/of satellietdata. Liefst zo ver mogelijk uitgewerkt in een voorbeeld-casus op één locatie, inclusief inzicht in nauwkeurigheid. Het uiteindelijke doel (voor vervolgstudies en projecten) is het kunnen detecteren en monitoren van steilrandlijnen langs de gehele Maas (of zelfs alle rivieren), en het toepassen van deze informatie voor schattingen van toekomstige erosie (door middel van een erosievoorspellingstool, bijv. de *htrend* tool).

Er kan ook gedacht worden aan een 'quick-scan' voor een eerste indicatie van potentiële erosielocaties, zonder al veel detail, en vervolgens in een later stadium een meer gedetailleerde aanpak (daadwerkelijke lijn detectie). Een quick-scan zou bijvoorbeeld o.b.v. (de verschillende versies van) AHN kunnen. Een toepassing met meerdere stappen is ook mogelijk, bijv.:

1. Quick-scan
2. Identificatie plekken waar veel verandering optreedt
3. Classificatie / gedetailleerde informatie van veranderingen
4. Voorspelling

¹ <https://www.satellietdataportaal.nl/>

Bij het bovenstaande zou ook uitgegaan kunnen worden van plekken waarvan je al weet dat ze 'hoog risico' hebben, om al een eerste focus aan te brengen. Zie ook Paragraaf 3.2.

Het is ook goed om rekening te houden met vergelijkbare lopende projecten, zoals bijvoorbeeld de SBIR (Small Business Innovation and Research) veranderingen in het watersysteem. Hier wordt ook gekeken naar rivieroeveren. De resultaten hiervan worden in 2021 verwacht.

Vanuit CIV wordt het liefst een modulaire aanpak voor nieuwe tools gezien. Dat wil zeggen, een 'module' die achter RWS front-end gehangen kan worden (er wordt hiervoor nu gekeken naar ESRI software) en dus niet nog een aparte tool.

Tenslotte is het voorspellen van erosie is erg lastig. Er zijn modellen, waar ook nog actief aan gewerkt wordt, die rekening houden met meerdere relevante zaken (bijv. golfafslag, vegetatie, bodemopbouw, hoogte van oever), maar sommige zaken vereisen ook nog meer onderzoek.

En als allerlaatste; hoewel tot nu toe steeds de eroderende oevers aangekaart zijn, ligt er ook een vraag om juist bestorting(randen) langs oevers te detecteren.

4 Voorbeeld-casus

De voorbeeld-casus had als doel om de verzamelde informatie toe te passen en methodes voor de automatische bepaling van steilrandlijnen te testen. Zoals aangegeven in het Plan van Aanpak was de uitvoering hiervan afhankelijk van eerder uitgevoerde werkzaamheden. In overleg is besloten om bij de casus niet naar één specifieke (voorkeurs)methode te kijken, maar om juist de voor- en nadelen van verschillende potentiële methodes toe te lichten.

Daarnaast diende de voorbeeld-casus als eerste vergelijking van beschikbare luchtfoto's en satellietbeelden. Luchtfoto's hebben een hogere ruimtelijke resolutie dan satellietbeelden en de vraag was of de resolutie van satellietbeelden geschikt was voor het automatisch bepalen van steilrandlijnen.

4.1 Methodes

Het bepalen van de steilrandlijnen kan op veel verschillende manieren gebeuren. Vanuit meerdere disciplines kunnen verschillende, maar soms ook overeenkomende, technieken gedeeld worden. Vanuit de aardobservatie en beeldbewerking discipline komen technieken als *index-based classification*, *object-based classification* en *change detection*. Vanuit de geografie (GIS) en geomatica hoek komen analyses op basis van hoogtekarten en puntwolken. En kunstmatige intelligentie (*artificial intelligence*, of AI) en de verschillende toepassingen daarvan (*machine learning* en *deep learning*) vindt zich ondertussen in zo goed als alle disciplines terug.

Er zijn uiteraard nog andere methodes te vinden en elke methode kan gecombineerd worden met bepaalde voor- en nabewerkingen, maar het valt buiten de scope van de voorbeeld-casus om daadwerkelijk alle mogelijkheden te onderzoeken. We leggen hieronder kort elke benoemde methode uit en geven ook aan of (en waarom) deze wel/niet gebruikt is in de casus. Wellicht ten overvloede, maar dit is niet een allesomvattende beschrijving van deze methodes. Het dient vooral om een beknopt overzicht van de mogelijkheden te geven.


Tabel 1 geeft een overzicht van de methodes die beschreven zijn in deze memo. Hierin is opgenomen of de methode op pixel niveau werkt (zo niet, dan wordt ook meer ruimtelijke informatie meegenomen), in hoeverre de methode afhankelijk is van ruimtelijke resolutie (i.e. in welke mate het succesvol toepassen van de methode gerelateerd is aan de resolutie van de gebruikte data), of er training nodig is voor de methode en of deze ook direct op andere locaties kan werken dan waar deze op getest/getraind is.

Tabel 1: Overzicht van hier beschreven potentiële steilrand detectie methodes

Methode	Op pixel niveau	Resolutie afhankelijk	Training nodig	Overall toepasbaar
<i>index-based</i>	Ja	Ja	Nee	Ja
<i>object-based</i>	Kan, niet noodzakelijk	Matig	Meestal wel	Meestal wel
<i>edge detection</i>	Ja	Ja	Nee	Ja
<i>change detection</i>	Meestal wel	Redelijk	Nee	Ja
<i>machine learning</i>	Kan, niet noodzakelijk	Matig	Ja	Hangt van toepassing af

4.1.1 Index-based classification

Dit type classificatie berekent eerst een relevante index kaart op basis van beschikbare data in de luchtfoto of het satellietbeeld. Deze bestaan uit meerdere zogeheten banden, vaak ten minste rood, groen en blauw (van waaruit samen een RGB beeld opgebouwd is), maar soms ook banden die buiten het waarnemingsveld van het menselijke oog vallen, zoals infrarood.



Figuur 4: Elektromagnetische golflengtes (wavelength) vs percentage transmissie in de atmosfeer, inclusief weergave van banden vanuit sensors op de Landsat 7 (onder) en Landsat 8 (boven) satellieten. (bron: <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview>)

Een index wordt berekend door een combinatie van banden. Hiervan is de meest bekendste waarschijnlijk de *Normalized Difference Vegetation Index* (NDVI), een combinatie van de rode en infrarood band. Door gebruik te maken van de groene en infrarood band kan een index die gevoelig is voor water berekend worden; de *Normalized Difference Water Index* (NDWI):


$$NDWI = \frac{(groen - NIR)}{(groen + NIR)}$$

hierin staat NIR voor near-infrared.

Deze methode werkt op (individueel) pixel-niveau. Dit heeft als voordeel dat de methode relatief efficiënt is qua benodigde rekenkracht (en tijd), omdat ruimtelijke patronen en andere zaken niet meegenomen hoeven te worden, en nadeel dat de methode juist hierdoor ook minder nauwkeurig kan zijn. De methode is hierdoor erg gevoelig door verstoringen in het beeld; als bepaalde pixels beïnvloed worden door ongewenste effecten (zoals bijv. vegetatie of schaduwen, zie ook de resultaten van de case studies verderop) dan zal dit direct effect hebben op het resultaat. Om dit probleem te verhelpen kan gebruik gemaakt worden van andere data-bronnen en/of een combinatie met andere methoden.


4.1.2 Object-based classification

In tegenstelling tot de vorige methode werkt de *object-based* versie juist niet op individueel pixel niveau. Deze methode probeert een grotere groep pixels te classificeren door te kijken naar verschillende eigenschappen (bijvoorbeeld de vorm). Deze methode kan hiernaast ook nog dezelfde informatie mee nemen als *index-based* classificatie (i.e. het spectrale signaal van de data). In dat geval kan de methode gezien worden als een uitbreiding op, of tweede stap na, *index-based* classificatie. Het is echter ook mogelijk om alleen ruimtelijke informatie mee te nemen en niet naar het spectrale signaal te kijken, vandaar dat deze methode ook apart benoemd wordt. Een schematische weergave van deze methode staat in Figuur 5.



Figuur 5: Schematisch overzicht van (de verschillende niveaus van) object-based classificatie (bron: Definiens Developer 7, User Guide, p. 26)

Het voordeel van deze methode is dat er meer informatie meegenomen kan worden waardoor deze potentieel een beter resultaat kan opleveren. Ook wordt hierdoor het effect van ruis op beelden (vanuit de sensor en/of door lokale condities) verminderd. Het nadeel is dat deze minder goed in staat kan zijn om kleine verschillen op te sporen. Zie ook Figuur 6, waarin duidelijk te zien is dat de *object-based* methode een resultaat met meer uniforme klassen heeft, zonder ruis. Dit betekent echter niet automatisch dat het resultaat ook beter is, omdat er ook details verloren kunnen gaan.




Figuur 6: Pixel (of index) based vs. object based classificatie (bron: Pandiwwijaya et al., 2013)

De toevoeging van ruimtelijke informatie maakt deze methode zwaarder qua benodigde rekenkracht dan de *index-based* versie, maar ook potentieel nauwkeuriger. Het goed opzetten van deze methode kan echter ook aanzienlijk meer werk zijn. Vanwege de extra tijd die nodig is voor het opzetten van de methode viel deze buiten de scope van de casus. Het is echter een potentieel geschikte methode die zeker aandacht verdient in een mogelijke vervolgstudie.

4.1.3 Edge detection

Ook deze methode werkt niet op individueel pixel niveau, maar gebruikt minder ruimtelijk contextuele informatie dan *object-based* classificatie. *Edge detection* kijkt naar veranderingen tussen naburige pixels, waarbij scherpe verandering geïdentificeerd worden als een *edge* (rand). Deze methode wordt al toegepast voor het classificeren van water, omdat de grens tussen land en water vaak een scherpe verandering is. Aangezien we bij het detecteren van steilrandlijnen juist geïnteresseerd zijn in die grens lijkt *edge detection* ook een geschikte methode voor het automatisch bepalen van steilrandlijnen.

Deze methode leent zich ook goed voor combinatie met andere methoden, zoals bijvoorbeeld gebruikt door Donchyts et al. (2016), zie ook Figuur 7.




Figuur 7: Combinatie van *index-based* en *edge detection* methoden voor classificatie van water (Donchyts et al., 2016)

4.1.4 Change detection

Deze methode is, in tegenstelling tot de eerder genoemde methodes, niet bedoeld voor toepassing op individuele beelden of datasets. *Change detection* is bij uitstek geschikt voor (lange) tijdreeksen, waarbij gekeken wordt naar hoe de data verandert door de tijd. Dit is in feite een zelfde soort methode als *edge detection*, waarbij niet gekeken wordt naar veranderingen tussen pixels op een zelfde beeld maar naar veranderingen in de tijd op meerdere beelden.

Dit is een methode die geschikt lijkt voor het bepalen van juist niet eroderende oevers. Hier zal immers geen enkele verandering optreden. Bij oevers waar wel verandering optreedt kan dit duiden op erosie, maar het zou ook om andere processen (bijv. menselijke ingrepen of versterking van het signaal door externe invloeden). Een goed voorbeeld van de toepassing van *change detection* in de water sector is de Aqua Monitor (Donchyts et al., 2016), zie Figuur 8.



Figuur 8: Toepassing van *change detection* voor classificatie van land en water (bron: Donchyts et al., 2016, <http://aqua-monitor.deltares.nl/>)

Dit is ook een methode die zich goed laat combineren met andere methodes. Het kan zo bijvoorbeeld dienen als eerste stap (een 'quick-scan') voor het bepalen van potentiële erosie locaties. Vervolgens kan op deze locaties een meer gedetailleerde analyse uitgevoerd worden.

4.1.5 Machine Learning

Machine Learning (ML) is een toepassing van AI. Bij deze methode wordt de machine (computer, server, algoritme) op een bepaalde manier getraind om vervolgens zelf te bepalen hoe de classificatie uitgevoerd moet worden. Typisch worden hier meerdere databronnen voor gebruikt zodat de machine kan bepalen welke data het belangrijkst is en hoeveel gewicht er aan elke toegekend moet worden. Om dit te kunnen bepalen is er wel een zogeheten training set nodig: een databron met gewenste resultaten die vooraf gemaakt is. Dit kan betekenen dat er vooraf meer werk uitgevoerd moet worden dan bij andere methodes. Het grote voordeel van ML is dat de methode hierna heel snel op andere (vergelijkbare) gebieden toegepast kan worden waar een zelfde soort classificatie nodig is. Daarnaast is het ook mogelijk om met deze methode inzicht te krijgen in wat voor soort data of processen belangrijk zijn. Dit is tot op zekere hoogte ook mogelijk met *object-based* classificatie, maar kan met ML veel uitgebreider toegepast worden.

Vanwege de hierboven genoemde extra tijd die nodig is voor het trainen van het model viel deze methode buiten de scope van de voorbeeld-casus. Het is echter een potentieel geschikte methode die zeker aandacht verdient in een mogelijke vervolgstudie.

4.2 Uitvoering

De voorbeeld-casus is gebruikt om bepaalde methodes te testen en vooral om meer inzicht te krijgen in potentiële problemen. Daarnaast is ook het effect van ruimtelijke resolutie getest, zodat aangegeven kan worden welke databronnen bruikbaar kunnen zijn en wat de potentiële nauwkeurigheid van elke databron is. Vanwege beperkingen in de beschikbare tijd is gekozen voor twee methodes die snel op te zetten zijn en die niet afhankelijk zijn van grote hoeveelheid data, namelijk *index-based classification* en *edge detection*.

4.3 Resultaten case studies


Er is op meerdere locaties gekeken naar de invloed van effecten op het automatisch bepalen van rivieroeveren. Locaties zijn uitgekozen op basis van zowel locatie-specifieke als tijdsafhankelijke effecten, of een combinatie daarvan. Tabel 2 geeft een overzicht van de verschillende onderwerpen, in welke databron deze optreden, wat de verwachte oorzaak is en welke oplossingen er zijn. Elk onderwerp is in meer detail uitgewerkt in de volgende paragrafen.

Tabel 2: Overzicht verschillende potentiële relevante onderwerpen bij automatische detectie van steilrandlijnen

Onderwerp	In lucht-foto (10cm)	In satelliet-data (2m)	Oorzaak probleem	Oplossing
Vegetatie land	Ja	Ja	obstructie signaal	data
Vegetatie water	Nee	Ja	gemengd signaal (probleem bij lagere resolutie data)	data, methoden, uitwerking
Schaduwen	Ja	Nee	minder scherpe grens water-land (probleem bij hogere resolutie data)	data, methoden
Tijdelijke objecten	Ja	Ja	obstructie signaal	data, methoden
Landgebruik	Ja	Ja	verstoring signaal	data, methoden
Niet steile oevers	Ja	Ja	gemengd signaal, minder scherpe grens water/land	data, methoden, nabewerkingen
Sediment	Nee	Nee	geen (potentieel verstoring signaal)	niet nodig (potentieel data)
Stranden	Nee	Ja	gemengd signaal, minder scherpe grens water-land	data, methoden
Resolutie	Nee	Ja	lagere resolutie	opschalen, nabewerkingen

4.3.1 Vegetatie op het land

Vegetatie langs de rivieroever kan het moeilijk maken om de daadwerkelijke rivieroever goed te detecteren. Zowel luchtfoto's als satellietbeelden zijn niet in staat om door dichte vegetatie heen te kijken. Dit is duidelijk zichtbaar in onderstaande figuren, waarin alleen een lijn langs de vegetatie afgeleid kon worden. Dit zou opgelost kunnen worden door de toevoeging en/of het gebruik van andere databronnen. LiDAR (bijv. AHN) kan wel door vegetatie heen kan dringen en metingen vanuit een boot kunnen daarnaast onder de vegetatie door kijken (afhankelijk van de type vegetatie).



Figuur 9: Effect van vegetatie op het land op potentiële oeverrand afgeleid uit 10cm luchtfoto (rode lijn) met 2cm luchtfoto als achtergrond

4.3.2 Vegetatie in het water

Ook vegetatie in het water kan het signaal verstoren, waardoor detectie van de rivieroever lastiger wordt. Een voorbeeld hiervan is te zien in onderstaande figuur. Het is duidelijk te zien dat vooral het satellietbeeld hier last van heeft. Dit wordt veroorzaakt door de lagere resolutie van deze data, waardoor pixels die zowel over de oever als het water (met daarin vegetatie) vallen een gemengd signaal krijgen en de grens tussen water en land minder duidelijk is. In het voorbeeld lijkt dit probleem minder aanwezig bij de hogere resolutie luchtfoto, maar het zou goed kunnen dat dit probleem ook bij deze data optreedt als de vegetatie dichter bij de oever is en/of duidelijker aanwezig is (e.g meer of ander soort vegetatie, dichter bij oppervlak).


Dit zou potentieel opgelost kunnen worden door de toevoeging en/of het gebruik van andere databronnen, vergelijkbaar als bij het probleem van vegetatie op land. Daarnaast kan de toevoeging en/of het gebruik van andere methoden, met name *object-based classification*, *change detection* en *machine learning* ook beter werken. Het kan echter ook zo zijn dat het relatief simpel op te lossen is door het gebruik van meerdere (satelliet)beelden en het afleiden van een bepaalde statistiek per pixel (bijv. gemiddelde of mediaan), een zgn. composietbeeld. Dit heeft impliciet een van de voordelen van *change detection*, namelijk dat vegetatie in het water waarschijnlijk niet altijd op dezelfde plek op dezelfde manier zichtbaar is op elk afzonderlijk beeld. Dit hangt uiteraard ook van de type vegetatie en lokale omstandigheden af.



Figuur 10: Effect van vegetatie in het water op potentiële oeverranden afgeleid uit een 2m satellietbeeld (links) en 10cm luchtfoto (rechts) met 2cm luchtfoto als achtergrond

4.3.3 Schaduwen

Grote, donkere schaduwen die gedeeltelijk over de oever en het water liggen kunnen het lastiger maken om rivieroeveren te detecteren, omdat deze ook het signaal enigszins verstoren. Dit hangt ook af van andere lokale condities. Wanneer de rest van het beeld geen of weinig andere potentieel problematische invloeden heeft dan lijken schaduwen geen probleem op te leveren voor de lagere resolutie satellietbeelden, maar juist wel voor de hogere resolutie luchtfoto's (zie Figuur 11). Dit wordt waarschijnlijk niet alleen veroorzaakt door de resolutie zelf, maar ook door het feit dat de satellietbeelden een infrarood band bezitten terwijl de hogere resolutie luchtfoto's alleen opgebouwd zijn uit de standaard RGB banden.




Figuur 11: Effect van schaduwen op potentiële oeverranden afgeleid uit een 2m satellietbeeld (rode lijn) en 10cm luchtfoto (gele lijn) met 2cm luchtfoto als achtergrond

Bij de hier toegepaste methode (*edge detection*) speelt resolutie ook wel een rol; er is door de schaduwen een minder duidelijke grens tussen water en land, waardoor kleinere verschillen in de vegetatie eerder opgepakt worden. Doordat deze bij de lagere resolutie satellietbeelden juist 'uitgesmeerd' zijn over grovere pixels is dit effect bij deze data verdwenen (en blijft alleen het effect van de vegetatie over zoals beschreven in Paragraaf 4.3.1).

Een vergelijkbaar effect kan optreden bij kleine schaduwen tussen objecten op het land, zoals te zien in Figuur 12. In het geval van de zeer hoge 2cm resolutie luchtfoto worden de schaduwen van individuele stenen opgepakt terwijl dit niet gebeurt bij het lagere resolutie satellietbeeld. Ook de luchtfoto van 10cm resolutie heeft dit probleem al veel minder.

Dit probleem kan potentieel opgelost worden door de toevoeging en/of het gebruik van andere data en methoden. Met name *edge detection* is erg gevoelig voor schaduwen. *Index-based classification*, met toevoeging van infrarood, heeft dit iets minder maar is ook niet volledig 'immuun'. Waarschijnlijk hebben *object-based detection* en bepaalde implementaties van *machine learning* hier het minste last van. Het gebruik van, of vooral de combinatie met, andere data (zonder het effect van schaduwen, zoals bijv. LiDAR) lijkt hier de meeste potentie te hebben.



Figuur 12: Effect van schaduwen bij kleine objecten (in dit geval stenen) op potentiële oeverranden afgeleid uit een 2m satellietbeeld (boven) en 10cm luchtfoto (onder) met 2cm luchtfoto als achtergrond

4.3.4 Tijdelijke objecten

Zowel luchtfoto's als satellietbeelden zijn een momentopname. Het kan dus zo zijn dat er objecten in voorkomen die tijdelijk van aard zijn, zoals voertuigen of boten. Een goed voorbeeld hiervan is te zien in Figuur 13, waarbij (een deel van) een aangemeerde veerboot zichtbaar is. Deze heeft een sterk contrast met de omgeving waardoor deze aangemerkt wordt als potentiële oeverrand bij gebruik van de *edge detection* methode. Een zelfde probleem is waarschijnlijk bij *change detection*, de andere methoden zullen dit probleem waarschijnlijk niet hebben. Bij alle methoden is het wel zo dat de oever onder het object niet zichtbaar is en dus wel voor problemen zal zorgen. De beste oplossing is hier waarschijnlijk de toevoeging en/of gebruik van andere data. Het is echter ook belangrijk om op te merken dat dit soort problemen waarschijnlijk minder snel zullen optreden bij daadwerkelijke steilranden, omdat de kans op tijdelijke objecten daar waarschijnlijk kleiner is.



Figuur 13: Effect van een tijdelijk object (in dit geval een veerboot) op de potentiële oeverranden afgeleid uit een 10cm luchtfoto met 2cm luchtfoto als achtergrond (90° gedraaid voor betere plaatsing op pagina)

4.3.5 Verschillend landgebruik

Op dezelfde locatie als gebruikt in de vorige paragraaf treedt ook een ander probleem op, namelijk het grote contrast tussen verschillende types landgebruik (in dit geval beton en vegetatie), waardoor dit ook als potentiële oeverrand geïdentificeerd zou kunnen worden. Dit speelt met name bij de *edge detection* methode. Een vergelijkbaar probleem kan optreden bij *change detection* voor gebieden waar plotselinge veranderingen optreden in het landschap (zoals bijvoorbeeld het oogsten van een akker). Dit probleem zal niet, of minder, aanwezig zijn bij de andere methoden. Ook het gebruik van andere data kan hier helpen, hoewel ook sommige andere data hier gevoelig voor kan zijn (bijvoorbeeld verandering in het landschap bij AHN). Een goede toevoeging bij *change detection* zou het beperken van de analyse tot alleen het gebied direct langs de rivier(oevers) zijn.

4.3.6 Niet steile oevers

Zoals ook al eerder aangegeven (zie o.a. Paragraaf 2.1 en 3.2) zijn locaties met daadwerkelijk steile oevers het meest interessant en ook het meest geschikt voor toepassing van de *htrend* tool. Voor automatische detectie is het echter ook van belang om minder steile oevers mee te nemen, aangezien deze ook aanwezig zijn langs de Maas (daarnaast kunnen ook oevers die nu nog steil zijn langzaam veranderen naar minder steile oevers, zie Figuur 3 in Paragraaf 2.1).

Bij dit soort oevers is het lastiger om de bovenkant (talud) van de oever te detecteren, omdat het makkelijker is om de grens tussen land en water te bepalen (en deze juist bij de onderkant van de oever zal zijn). Het effect hiervan is goed zichtbaar in Figuur 14. In dit geval lijkt het nog wel mogelijk om automatisch zowel de onder- als bovenkant van de oever te detecteren, hoewel het op sommige plekken duidelijk minder goed werkt. Op het lagere resolutie satellietbeeld is

het moeilijker om in te schatten wat het effect van zo'n soort oever is. Er lijkt wel iets van een verschuiving zichtbaar op de plek waar er duidelijk een lagere oever is, dus het is aannemelijk dat dit ook invloed heeft op detectie vanuit satellietbeelden.



Figuur 14: Effect van een minder steile oever op potentiële oeverranden afgeleid uit een 10cm luchtfoto (boven) en 2m satellietbeeld (onder) met 2cm luchtfoto als achtergrond

In het geval van de detectie van zowel de onder- als bovenkant van de oever kunnen deze waarschijnlijk simpelweg gescheiden worden door de afstand tot de rivier te bepalen (waarbij een langere afstand de hogere oever aangeeft). Ook kan gebruik gemaakt worden van meer

data, zoals bijv. LiDAR hoogtekarten (AHN), waarmee ook de hogere en lagere oever van elkaar gescheiden kunnen worden.

In het geval van het niet goed kunnen bepalen van de juiste (bovenste) oever is een andere aanpak vereist. Hier is het waarschijnlijk nodig om meer data en/of andere methoden toe te passen, of een combinatie daarvan. Zowel *edge detection* als *index-based classification* zullen waarschijnlijk problemen ondervinden. *Change detection* is heel afhankelijk van de lokale veranderingen, maar het is aannemelijk dat ook deze methode problemen zal hebben. *Object-based classification* en bepaalde toepassingen van *machine learning* hebben in theorie de meeste potentie, maar er kan desalniettemin veel tijd gaan zitten in het vinden van de juiste methode (en de juiste parameters voor die methode).

4.3.7 Sediment in water

De kleur van water (of beter gezegd, de reflectie van licht zoals opgepakt door verschillende sensoren) hangt veel af van de hoeveelheid en soort sediment in het water. Dit kan potentieel tot problemen leiden bij het detecteren van steilrandlijnen langs rivieroeveren. Echter, in deze voorbeeld-casus leek dit geen daadwerkelijke problemen te geven, zoals te zien in Figuur 15. Hierin is duidelijk zichtbaar dat het sediment geen effect lijkt te hebben op het bepalen van de oeverrand. Het verschil tussen land en (sediment-rijk) water is blijkbaar nog steeds groot genoeg. Dit betekent echter niet dat dit nooit tot problemen zal leiden. Op andere locaties, onder andere omstandigheden en/of bij het gebruik van andere methoden zou dit potentieel wel voor problemen kunnen zorgen. Met name het bij samenvallen met andere problemen (zoals bijv. vegetatie en/of schaduwen) is het aannemelijk dat dit de automatische detectie negatief kan beïnvloeden. Het is echter niet gelukt om deze situaties mee te nemen in deze studie.



Figuur 15: Effect van hoge sediment concentraties in het water op potentiële oeverranden afgeleid uit een 2m satellietbeeld (rode lijn) en 10cm luchtfoto (gele lijn) met 2cm luchtfoto als achtergrond

4.3.8 Stranden

Stranden (of zandbanken) langs de rivieroeveren kunnen een vergelijkbaar effect hebben als ander landgebruik (Paragraaf 4.3.5) minder steile oevers (Paragraaf 4.3.6) en/of sediment (Paragraaf 4.3.7); het kan het lastiger maken om de bovenste oever (talud) te vinden. In deze voorbeeld-casus leek dit vooral een probleem met lagere resolutie satellietdata en minder bij hogere resolutie luchtfoto's, zie Figuur 15. Doordat het verschil tussen de oever en het strand bij hogere resolutie nog groot genoeg is wordt de oever hier goed opgepakt en lijkt het strand geen (of weinig) invloed te hebben. Bij de lagere resolutie satellietdata geeft het duidelijk wel problemen. Een potentiële oplossing voor dit probleem kan gevonden worden door te kijken bij de vergelijkbare problemen; de toevoeging en/of het gebruik van andere data alsmede andere methoden. Waarschijnlijk hebben stranden effect op alle methoden bij gebruik van lagere resolutie data, hoewel goed ontworpen *object-based classification* en *machine learning* methodes het beste lijken om hiermee om te gaan.



Figuur 16: Effect van aanwezigheid van stranden op potentiële oeverslijnen afgeleid uit een 10cm luchtfoto (boven) en 2m satellietbeeld (onder) met 2cm luchtfoto als achtergrond

4.4 Resultaten resolutie-effect


Om het effect van de verschillende resoluties in kaart te brengen is gebruik gemaakt van locaties met vaste oevers (zoals voorgesteld tijdens de expert-sessies, zie Paragraaf 3.2). Hier is het zeker dat potentiële verschillen veroorzaakt worden puur en alleen door de resolutie en niet door veranderingen in de ligging van de oever.



Figuur 17: Vergelijking van potentiële oeverranden afgeleid uit data met verschillende resoluties (zwart: 2m satellietbeeld, rood: 10cm luchtfoto, groen: referentie, handmatig getrokken uit 2cm luchtfoto)

In Figuur 17 is het effect van resolutie duidelijk te zien. De satellietdata met een resolutie van 2 meter heeft een kenmerkend getrapt verloop (i.e. *staircase effect*), waarbij de individuele pixels duidelijk zichtbaar zijn. Dit is veel minder het geval bij de hogere resolutie luchtfoto van 10cm. Zoals ook eerder vermeld is het ook mogelijk om de satellietdata naar een hogere resolutie te tillen (tot 50cm), waarbij dit effect uiteraard minder sterk aanwezig zal zijn. Daarnaast is het ook mogelijk om een nabewerking toe te passen om een meer vloeiende lijn te krijgen, bijvoorbeeld door ruimtelijke interpolatie met berekening van de gemiddelde ligging. In de figuur is te zien dat er zowel een onder- als overschatting van de oeverlijn is (meer in de rivier en meer op land), waardoor zo'n nabewerking een gunstig effect zou kunnen hebben.

Er is ook in meer kwantitatieve termen naar de verschillen op deze locatie gekeken. Het maximale verschil tussen de referentielijn en de 2 meter data was 2.6m, terwijl deze voor de 10 cm data zelfs 3.5m was. Dit is echter te verklaren doordat schaduwen hier voor problemen zorgen bij de hogere resolutie data (zie Paragraaf 4.3.3). Wanneer de grote uitschieters weggenomen worden daalt het maximale verschil tot 1.5m. Maar ook hier zitten nog locaties met schaduwen tussen. Visueel is echter wel vast te stellen dat, wanneer de problemen met schaduwen opgelost worden, de 10cm resolutie data veel dichterbij de referentielijn komt dan de 2m resolutie data.



Figuur 18: Vergelijking van potentiële oeverranden afgeleid uit data met verschillende resoluties (links: 2cm luchtfoto, rechts: 10cm luchtfoto)

Figuur 18 laat het verschil tussen de 2 en 10 cm resolutie luchtfoto's zien. Los van de problemen op deze locatie (zie o.a. Paragraaf 4.3.4) lijkt er geen groot verschil tussen deze resoluties te zijn.

4.5 Conclusies voorbeeld-casus

Op basis van de hierboven beschreven resultaten komen wij tot de volgende conclusies:

- Het is mogelijk om steilrandlijnen automatisch te detecteren vanuit luchtfoto's en/of satellietbeelden, maar voordat dit echt operationeel gebruikt kan worden moeten er nog oplossingen voor verschillende problemen gevonden worden
- Het toepassen van extra databronnen, specifiek gebaseerd op LiDAR data (zoals bijv. de hoogtekarten van het AHN), heeft veel potentie voor het (gedeeltelijk) oplossen van deze problemen en wordt dan ook aangeraden
- Het toepassen van andere methodes voor automatische detectie, of een combinatie daarvan, heeft ook veel potentie. Met name *object-based classification* en *machine learning* applicaties lijken erg geschikt. Dit zijn wel methodes die in de uitwerkingsfase meer tijd kosten om op te stellen.
- Met sommige simpele voor- en nabewerkingen kan waarschijnlijk ook al veel winst geboekt worden, hoewel dit zeker niet alle problemen kan oplossen
- Ruimtelijke resolutie heeft zeker een effect op de resultaten. Het effect hangt af van verschillende factoren en er zijn mogelijkheden om dit effect te verkleinen. De toepassing hangt ook af van het gebruik (voor sterkere erosie kan met lagere resolutie data gewerkt worden)

Om nog iets dieper in te gaan op de ruimtelijke resolutie. Uit deze voorbeeld-casus volgt dat satellietdata op redelijke hoge resolutie (i.e. 2 meter) waarschijnlijk niet goed genoeg is voor een nauwkeurige bepaling van steilrandlijnen. Dit hangt uiteraard ook af van de specifieke toepassing en hoe sterk de erosie is (bij sterkere erosie kan waarschijnlijk met lagere resolutie data gewerkt worden). Ook zijn er nog nabewerkingen mogelijk om tot hogere nauwkeurigheid te komen. Van de standaard openbare satellietdata kan wel gezegd worden dat deze resolutie (op dit moment tot 10 meter) niet geschikt is, hoewel het voor een quick-scan nog potentie zou kunnen hebben. Satellietdata op de hoogst mogelijke resolutie (op dit moment 50cm) is waarschijnlijk wel geschikt voor het bepalen van steilrandlijnen. Luchtfoto's op 10cm resolutie waren ruim voldoende, waarbij het gebruik van nog hogere resolutie (2cm) weinig leek toe te voegen. Data op hogere resolutie had soms juist problemen die niet aanwezig waren bij data op lagere resolutie, maar waarschijnlijk kunnen deze door eerder genoemde verbeterpunten opgelost worden.

5 Conclusies

De in dit document beschreven verkenningstudie had als doel om meer inzicht te verkrijgen in de mogelijkheden voor het automatisch bepalen van steilrandlijnen langs de Maas. Op locaties waar de oevers langs de rivier teruggebracht zijn naar een meer natuurlijke staat treedt meer erosie op dan in het verleden en in sommige gevallen kan dit ook tot problemen leiden. Het op tijd signaleren van probleemlocaties is één van de benodigde stappen om hier goed mee om te kunnen gaan. Dit vereist een goede aanpak voor het monitoren van de rivieroever. Eén van de wensen vanuit Rijkswaterstaat, specifiek het Team Uiterwaardenbeheer, is om het handwerk dat hier tot nu toe bij komt kijken meer te automatiseren. Deze studie dient als eerste aanzet en kan gebruikt worden bij het vormgeven van vervolgstudies en projecten.

De studie is tweedelig opgezet: er zijn allereerst expert-sessies georganiseerd waarbij zowel experts als (potentiële) gebruikers vanuit Rijkswaterstaat, IHE Delft en Deltares aan konden sluiten. Door deelnemers is ook nog extra informatie aangeleverd buiten de sessies om. Dit is gebruikt voor de meer theoretische / achtergrond informatie in dit memo. Als tweede is er een voorbeeld-casus opgezet, waarbij op verschillende locaties en met behulp van verschillende data gekeken is naar de potentie voor het automatisch bepalen van steilrandlijnen en welke problemen hier naar voren kwamen. Dit is gebruikt voor de meer praktische inhoud in dit memo.

Uit de expert-sessies is gebleken dat er zowel bij Rijkswaterstaat als Deltares veel collega's met relevante kennis rondlopen en dat het onderwerp erg leeft binnen beide organisaties. Hoewel geprobeerd is om zoveel mogelijk hiervan op papier te zetten, kan dit nooit volledig in een memo gevangen worden. Het wordt dan ook aangeraden om deze collega's betrokken te houden bij relevante vervolgstappen. Niet alleen vanwege hun kennis, maar ook vanwege hun inzicht en betrokkenheid bij andere initiatieven die hier raakvlak mee hebben.

Ook is gebleken dat er veel potentieel nuttige data ligt die nu nog niet optimaal gebruikt wordt. Te denken valt aan hoge resolutie satellietdata, beschikbaar via het NSO satellietdataportaal, en LiDAR hoogtemetingen, bijvoorbeeld het Actueel Hoogtebestand Nederland (AHN). Uit de voorbeeld-casus blijkt ook dat juist de combinatie van verschillende databronnen heel sterk kan zijn, omdat hiermee mogelijke problemen in één databron opgevangen kunnen worden door een andere.

Daarnaast kan het gebruik van meerdere databronnen ook een rol spelen bij een suggestie die door meerdere experts gemaakt is, namelijk het opzetten van een toepassing met meerdere lagen, waarbij in verschillende stappen steeds in meer detail gekeken wordt. Dit zou er als volgt uit kunnen zien (waarbij de quick-scan zowel op het gehele rivierengebied plaats zou kunnen vinden, of eerder al beperkt is tot mogelijke risicolocaties):

1. Quick-scan
2. Identificatie plekken voor verdere analyse
3. Classificatie / gedetailleerde informatie
4. Voorspelling

De voorbeeld-casus heeft aangetoond dat het in principe mogelijk moet zijn om automatisch de steilrandlijnen langs de Maas te bepalen. Het heeft echter ook laten zien dat er goed rekening gehouden moet worden met een aantal zaken die tot problemen kunnen leiden. Naast het eerder al genoemde gebruik van meerdere databronnen wordt het ook aangeraden om andere, veelbelovende methoden te testen, die nu buiten de scope van de studie vielen.

In de voorbeeld-casus is ook het effect van ruimtelijke resolutie meegenomen. Hieruit volgt dat deze data op de hoogst mogelijke resolutie (op dit moment 50cm) waarschijnlijk geschikt is voor de automatische bepaling van steilrandlijnen. Uiteraard zijn er verschillen met nog hogere resolutie data uit luchtfoto's. Of bepaalde data daadwerkelijk gebruikt moet worden hangt niet

alleen af van de ruimtelijke resolutie, maar ook van de beschikbaarheid, specifieke toepassing en het uiteindelijke doel dat deze moet dienen.

Tenslotte is het belangrijk om te benadrukken dat de voorbeeld-casus slechts een beperkte test heeft kunnen uitvoeren. Hoewel hier waardevolle informatie uit is gekomen kan niet verwacht worden dat deze allesomvattend is; er kunnen bij een groter opgezette studie nog andere problemen naar voren komen en de potentiële oplossingen die hier voorgesteld zijn hebben nog geen praktijktest ondergaan. Het wordt dan ook aangeraden om hier bij vervolgstappen rekening mee te houden en niet alleen op de uitkomsten van deze beperkte studie te vertrouwen.

6 Referenties

Definiens. 2007. Definiens Developer 7 User Guide. Munich, Germany.

Donchyts, G., Schellekens, J., Winsemius, H., Eisemann, E. & van de Giesen, N. (2016). A 30 m Resolution Surface Water Mask Including Estimation of Positional and Thematic Differences Using Landsat 8, SRTM and OpenStreetMap: A Case Study in the Murray-Darling Basin, Australia. *Remote Sensing*, 8(5):386, doi:10.3390/rs8050386

Donchyts, G., Baart, F., Winsemius, H., Gorelick, N., Kwadijk, J. & van de Giesen, N. (2016). Earth's surface water change over the past 30 years. *Nature Climate Change*, 6(9), doi:10.1038/nclimate3111

Pandiwijaya, A., Vanesza, A., Ekadinata, A., Dewi, S. & Prasetyo, A. (2013). *Hierarchical Object-Based Classification System for Land Use/Cover Mapping of Vietnam*. Proceedings of the Asian Conference of Remote Sensing 2013.

Peters, B. (2005). *Vrij Eroderende Oevers langs de Maas – Landschapsecologisch Streefbeeld*. Studie in opdracht van Rijkswaterstaat Limburg Bureau Drift. 38 p.

de Ruiter, T., A. Fioole en A. Sieben (2017). *Memorandum Prognose bodemveranderingen met heterogene bodemdynamiek*. RWS-memo 11-05-2017.

Sinnige, R. en Becker, A. (2019). *Voorspelling van lokale bodemligging door extrapolatie van horizontale trends*. Deltares rapport 11203681-008-ZWS-0005 in opdracht van Rijkswaterstaat Water, Verkeer & Leefomgeving.