




Inzet van sensoren voor evaluatie bodemkwaliteit BLN

Gerard H. Ros

Yuki Fujita

Janjo de Haan

Referaat

Ros GH, Fujita Y & J de Haan (2023). *Inzet van sensoren voor evaluatie bodemkwaliteit BLN*, Nutriënten Management Instituut BV, Wageningen, Rapport 1819.N.23.B, 27 pp.

Rapport in het kort

Duurzaam bodembeheer vereist integrale aandacht voor de fysische, chemische en biologische bodemkwaliteit. Binnen de PPS Beter Bodem Beheer is hiervoor een integrale systematiek ontwikkeld om landbouwbodems te meten én de kwaliteit ervan te beoordelen. Omdat veel bodemmetingen kostbaar zijn, biedt de inzet van bodemsensoren perspectief. Dit rapport beschrijft een kleinschalige evaluatie van de inzet van sensoren om chemische, fysische en biologische parameters te meten, gebruik makend van data uit het Bedrijvensnetwerk Bodemmetingen. Sensoren bieden veel potentie om bodemkenmerken voor de BLN meetbaar te maken.

© 2023 Wageningen, Nutriënten Management Instituut NMI B.V.

Alle rechten voorbehouden. Niets uit de inhoud mag worden verveelvoudigd, opgeslagen in een geautomatiseerd gegevensbestand, of openbaar gemaakt, op welke wijze dan ook, zonder voorafgaande schriftelijke toestemming van de directie van Nutriënten Management Instituut NMI.

Rapporten van NMI dienen in eerste instantie ter informatie van de opdrachtgever. Over uitgebrachte rapporten, of delen daarvan, mag door de opdrachtgever slechts met vermelding van de naam van NMI worden gepubliceerd. Ieder ander gebruik (daaronder begrepen reclame-uitingen en integrale publicatie van uitgebrachte rapporten) is niet toegestaan zonder voorafgaande schriftelijke toestemming van NMI.

Disclaimer

Nutriënten Management Instituut NMI stelt zich niet aansprakelijk voor eventuele schadelijke gevolgen voortvloeiend uit het gebruik van door of namens NMI verstrekte onderzoeksresultaten en/of adviezen.



Beter Bodembeheer

Verspreiding

PPS Beter Bodem Beheer

digitaal

Inhoudsopgave

Samenvatting en conclusies	2
1 Inleiding	3
2 Materiaal en methode	5
2.1 Bodemanalyses	5
2.2 Sensoren	6
2.3 Statistische analyse	7
3 Resultaten	8
3.1 Algemeen	8
3.2 Organische stof kengetallen	8
3.3 Chemische bodemkenmerken	10
3.4 Biologische bodemkenmerken	13
3.5 Fysische bodemkenmerken	16
4 Discussie en Conclusie	20
Literatuur	22
Bijlage A. Statistische analyse	23
Bijlage B. Resultaten	26

Samenvatting en conclusies

Op basis van twee jaren aan meetgegevens vanuit het Bedrijvennetwerk Bodemmetingen is onderzocht of het mogelijk is om de benodigde bodemkenmerken voor een analyse en beoordeling van de bodemkwaliteit conform de systematiek van Bodemindicatoren Landbouwgronden Nederland, BLN met enkele aanvullende metingen ook via bodemsensoren in kaart te brengen. Hierbij is gebruik gemaakt van sensoren die in Nederland inzetbaar zijn, en waarmee het grootste deel van de fysische, chemische en biologische kenmerken te meten zou zijn. Hiervoor is gebruik gemaakt van een indirecte statistische analyse.

De potentiële inzet van sensoren is geëvalueerd voor het meten van:

- **Organische stof parameters:** het gehalte aan organische stof of koolstof, de fractie koolstof extraheerbaar met heet water (HWC) of te oxideren via permanganaat (POX-C) of via pyrolyse (inclusief de afgeleide I – en R – indexen).
- **Chemische parameters:** de CEC, de zuurgraad, en het gehalte aan fosfaat (P-water, P-CaCl₂ or P-AL) en de voorraad van beschikbaar kalium.
- **Biologische parameters:** de potentiële mineraliseerbare stikstof (PMN), PLFA, en het gehalte Ergosterol en de biomassa van bacteriën, schimmels, Actinobacteria en Grampositieve bacteriën.
- **Fysische parameters:** kleigehalte, watervasthoudend vermogen, het vochtgehalte bij pF₂, de bulkdichtheid en de hoeveelheid waterstabile aggregaten.

Voor vrijwel alle parameters is de voorzichtige conclusie dat het mogelijk is om via sensoren inzicht te geven in de ruimtelijke variatie die op kan treden als gevolg van natuurlijke omstandigheden en het gevoerde management op akkerbouwbedrijven. Deze studie is *niet* opgezet om de daadwerkelijke meetonzekerheid van sensoren te kwantificeren; daarvoor is de dataset te klein en zijn de sensoren niet gekalibreerd. Desondanks was het mogelijk om voor het grootste deel van de BLN-metingen een betrouwbare schatting te geven: de afwijking is vrijwel nooit groter dan één keer de standaarddeviatie, de verbanden zijn sterk significant, en de puntenbias ligt gemiddeld rond de nul. Dit suggereert dat de sensorleveranciers met een beperkte uitbreiding van hun kalibratieset, en gekoppeld aan *deep learning* modellen die ook in staat zijn om niet-lineaire patronen te verdisconteren, het mogelijk kunnen maken om het grootste deel van de BLN-metingen betrouwbaar, robuust en goedkoop te meten.

Omdat de ruimtelijke variatie in het veld substantieel kan zijn, hebben sensoren naast de kosten een aanvullend voordeel boven klassieke metingen. Sensoren worden gekenmerkt door een hoge precisie, wat betekent dat bij herhaalde metingen de fout erg klein is. Binnen het veld kunnen daarnaast meerdere metingen worden uitgevoerd, waardoor het mogelijk is om een robuuste schatting te krijgen van het gemiddelde per perceel. Uiteraard is dit zeer sterk afhankelijk van de kwaliteit van de onderliggende database waarop de sensoren zijn gekalibreerd als ook de gebruikte kalibratiemethode. De conclusies uit dit rapport zijn daarom niet generiek toepasbaar op alle beschikbare sensoren in Nederland.

In conclusie: sensoren bieden veel potentie om bodemkenmerken voor de BLN meetbaar te maken.

1 Inleiding

De landbouw staat anno 2022 voor een aantal grote duurzaamheidsvraagstukken, waaronder het produceren van voldoende en gezond voedsel als ook het leveren van ecosysteemdiensten om de kwaliteit van de lokale leefomgeving te bevorderen. De bodem speelt bij deze uitdagingen een sleutelrol. Dat wordt niet alleen zichtbaar in het Nationale Programma Landbouwbodems en de LNV-visie rond kringlooplandbouw, maar ook in het klimaatakkoord, de herijking van het mestbeleid, het 7e stikstofactieprogramma, en de Kaderrichtlijn Water. Het uiteindelijke streven van het ministerie van Landbouw is dan ook om in 2030 alle landbouwbodems duurzaam te beheren.

Een goede bodemkwaliteit, ofwel een gezonde of vitale bodem, is van onschatbare waarde. Gezonde bodems leveren namelijk een groot aantal ecosysteemdiensten, zoals klimaatregulatie, primaire productie en bescherming tegen erosie (Rinot et al., 2019; Bünemann et al., 2018). Onzorgvuldig beheer kan leiden tot een achteruitgang van de bodemkwaliteit (RLI, 2020; TCB, 2016; Van den Akker, 2019). Intensieve agrarische bedrijfsvoering kan resulteren in verzuring, vermesting, verdroging, en verdichting van de bodem. Extensieve vormen van bodem- en gewasbeheer kunnen zorgen voor lagere opbrengsten, minder koolstofopbouw en hogere verliezen van fosfaat. Verder kan intensief beheer de bodem minder weerbaar maken voor bodem-gerelateerde ziektes en plagen (Radnadass et al., 2012). Onzorgvuldig beheer leidt daarmee tot lagere opbrengsten, vermindering van biodiversiteit, eutrofiëring van oppervlaktewater, minder waterberging en hogere uitstoot van broeikasgassen (De Vries et al., 2022; Gomet & Reidsma, 2021). Desondanks laat de praktijkervaring en het agronomisch onderzoek zien dat de huidige landbouwbodems een goede kwaliteit hebben om een duurzame voedselproductie te faciliteren (Ros et al., 2022; Van den Elsen et al., 2020).

De kwaliteit van de bodem wordt internationaal gedefinieerd als *"de capaciteit van de bodem om te functioneren als een vitaal levend systeem, binnen de grenzen van het ecosysteem en het landgebruik, om de productiviteit van planten en dieren in stand te houden of te verbeteren, de water- en luchtkwaliteit te verbeteren, en het bevorderen van de gezondheid van planten en dieren"* (Bonfante et al., 2020). Waar bodemgezondheid zich richt op de daadwerkelijke bijdrage die de bodem levert, daar richt zich bodemkwaliteit op de intrinsieke bijdrage die een specifieke bodem kan leveren, afhankelijk van grondsoort, klimaat, bouwplan en bodembeheer. In beide gevallen wordt gekeken naar de functies en ecosysteemdiensten die de bodem levert, waarbij een ecosysteemdienst wordt gevormd door een verzameling bodemfuncties. Binnen Nederland wordt dit binnen beleid en onderzoek concreet gemaakt voor: i) een duurzame productie van landbouwgewassen, ii) voldoende waterafvoer -beschikbaarheid, iii) extra koolstofvastlegging, iv) verbetering van biodiversiteit, en v) een hoge nutriëntenbenutting om verliezen naar lucht en water te voorkomen.

Voortbouwend op tientallen jaren landbouwkundig onderzoek, opgebouwde expertise binnen nationale meetnetten en inzichten vanuit tools als Soil Health Index, BodemQ en de Soil Navigator, is in 2019 de set Bodemindicatoren voor Landbouwgronden in Nederland (BLN) als ook de Open Bodemindex (OBI) ontwikkeld (Ros et al., 2022; Hanegraaf et al., 2019). De BLN set is opgezet om concreet te maken welke bodemkenmerken minimaal gemeten moeten worden om inzicht te krijgen in de bodemkwaliteit en -gezondheid. Samen met de praktijk hebben kennisinstellingen daarnaast gewerkt aan een integrale beoordelingssystematiek, die vanaf 2023 zijn geïntegreerd binnen de BLN versie 2.0.

Om een zinnige uitspraak te doen over de kwaliteit en gezondheid van de bodem zijn allereerst metingen en waarnemingen cruciaal, hierna bodemkenmerken genoemd. Elk bodemkenmerk moet daarna worden geïnterpreteerd in het licht van een gewenste situatie. Meetmethoden moeten i) voldoende nauwkeurig en precies zijn om veranderingen in management te kunnen detecteren, ii) bij voorkeur routinematig in een agrarisch laboratorium gemeten kunnen worden om kosten te reduceren, iii) snel en praktisch uitvoerbaar zijn en iv) niet te dynamisch zijn in afhankelijkheid van weersomstandigheden. Omdat veel meetmethodes niet voldoen aan alle criteria tegelijk is in de BLN 1.1 onderscheid gemaakt in de klassieke meetmethoden (meestal nauwkeurig en precies) en alternatieve meetmethoden (meestal snel, goedkoop en betrouwbaar genoeg voor een kwaliteitsbeoordeling). Klassieke meetmethoden meten vaak de bodemeigenschap direct terwijl de alternatieve meetmethoden vaak gebaseerd zijn op indirecte metingen waarbij gebruik wordt gemaakt van sensoren (XRF, NIR of MIR), eDNA sequencing of pedotransferfuncties afgeleid van grote datasets. De oorspronkelijke systematiek van BLN 1.0 waarbij de gewenste meetmethode geselecteerd kon worden op basis van een gewenste nauwkeurigheid blijft hiermee staan. De systematiek geeft enerzijds een default resultaat maar is echter ook zo flexibel dat een gebruiker de default methoden voor elke bodemfunctie kan aanpassen voor de eigen situatie en doelstellingen, uiteraard binnen algemene randvoorwaarden voor statistische betrouwbaarheid en reproduceerbaarheid. Wel is gekozen om in de BLN 2.0 de snelle goedkopere methode de standaard te maken omdat deze voor de meeste gebruikers relevant is.

Er zijn in Nederland diverse (mobiele) sensoren op de markt om bodemeigenschappen te meten, gericht op het meten van bodemvocht (Kool et al., 2022), bodemdichtheid (de Haan et al., 2021) of bodemvruchtbaarheid (Riechelman et al., 2021; Hanegraaf et al., 2012). Uit diverse onderzoeken bleek dat de verschillen tussen sensoren zo nu en dan behoorlijk groot zijn, zowel qua gebruikersgemak als de betrouwbaarheid (Kool et al., 2022; Kempenaar et al., 2018). Het bepalen van een absoluut niveau van de bodemvochttoestand blijkt zelfs met ringmonsters lastig, vochtgehalte en trends worden over het algemeen goed gevolgd door de verschillende sensoren. Bij de bodemsensoren wordt vaak onderscheid gemaakt naar sensoren voor vlakdekkende metingen en puntmetingen, waarbij vlakdekkende sensoren inzicht geven in de ruimtelijke variatie binnen percelen en puntmetingen inzicht geven in de kwaliteit van een mengmonster of individueel monsterpunt. Sensoren maken gebruik van een meetwaarde via elektromagnetische geleidbaarheid, natuurlijke radioactiviteit of lichtreflectie (NIR, MIR, VIS), waarbij op basis van een kalibratieset een relatie is gelegd met bodemkenmerken. Voor veel sensoren geldt dat de textuur van de bodem, het klei-, silt-, zand-, organische-stofgehalte, soms de pH en soms bepaalde nutriënten goed in kaart kunnen worden gebracht (Postma, 2023).

Binnen de context van de PPS Beter Bodembeheer is een verkennend onderzoek uitgevoerd om inzicht te krijgen in de potentiële inzet van mobiele bodemsensoren om ruimtelijke variatie in chemische, biologische en fysische bodemkenmerken in kaart te brengen. Hiervoor is gebruik gemaakt van bodemanalyses vanuit het Bedrijvennetwerk Bodemmetingen. Dit is een verkennend onderzoek omdat de gebruikte sensoren niet gekalibreerd zijn voor al de onderzochte bodemkenmerken als ook dat het aantal grondmonsters te klein is voor een robuuste analyse van de meetfout.

2 Materiaal en methode

2.1 Bodemanalyses

Het Bedrijvennetwerk Bodemmetingen van de PPS Beter Bodembeheer is in het najaar 2018 opgezet met als doel om bodemmetingen op praktijkbedrijven te testen en te kijken naar de samenhang van bodemindicatoren onderling en met de bedrijfsvoering. De 16 bedrijven vertegenwoordigen de variatie in de akkerbouw in Nederland en vormen daarmee een landsdekkend netwerk. Bij elk bedrijf zijn twee percelen geselecteerd in overleg met de ondernemer waarna de bodemindicatoren van de BLN (versie 1.0) zijn geanalyseerd. De 16 bedrijven beslaan verschillende regio's, grondsoorten en bouwplannen. Aangenomen wordt dat de verzamelde gegevens en kennis een goede doorsnede opleveren van relevante gegevens over de gangbare akkerbouw in Nederland. Het netwerk is te beperkt van omvang om ook representatief te kunnen zijn. De keuze van bedrijven is gedaan om alle belangrijke grondsoorten-regiocombinaties af te dekken en dat op deze wijze voor de meeste akkerbouwers in Nederland een herkenbaar bedrijf qua grondsoort en bedrijfsvoering beschikbaar is. Uitgebreide documentatie over deze metingen is te vinden in de Haan et al. (2021).

In het najaar van 2019 zijn meer dan 30 verschillende bodemindicatoren gemeten op twee percelen van elk bedrijf vanuit de werkpakketten rond organische stof, bodembiologie en bodemweerbaarheid en meten van bodemkwaliteit in de PPS Beter Bodembeheer. Hierbij zijn zowel alle indicatoren uit de BLN-indicatorset gemeten, zowel met de klassieke meetmethodes als de alternatieve (goedkopere en/of snellere) meetmethodes als een aantal andere indicatoren. Hiernaast zijn ook teeltgegevens en historische gegevens van de percelen verzameld. Doel van de metingen was om 1) een beter zicht te krijgen op de toepasbaarheid van de indicatoren en meetmethoden in de BLN, 2) alternatieve indicatoren en meetmethoden te testen, 3) een beter inzicht te krijgen in de relatie tussen indicatoren onderling, de indicatoren en de fysieke omstandigheden (bodemtype, klimaat, grondwater) en de indicatoren en het management, 4) na te gaan welke set aan indicatoren leidt tot een goed beeld van de integrale bodemkwaliteit mede gezien ook het management en de fysieke omstandigheden.

In de periode tussen 23 september 2019 en 11 november 2019 heeft er een uitgebreide meetcampagne plaatsgevonden. De toegepaste protocollen voor bemonstering en analyse worden uitgebreid beschreven door de Haan et al. (2021). Veel van de gemeten bodemparameters zijn opgenomen in de indicatorset Bodemindicatoren voor Landbouwgronden in Nederland (BLN, Hanegraaf et al., 2019). In deze indicator set is onderscheid gemaakt tussen klassieke bepaling (K) en alternatieve bepaling (A) van de indicatoren. Klassieke methodes zijn over het algemeen relatief nauwkeurig en betrouwbaar. Alternatieve methodes zijn over het algemeen relatief snel en goedkoop, hebben een hoge betrouwbaarheid (*high precision*), maar minder nauwkeurig (*moderate accuracy*). Zowel de betrouwbaarheid als nauwkeurigheid hangen sterk samen met de onderliggende kalibratieset en gebruikte kalibratiemethoden.

In 2021 is dezelfde bemonstering herhaald, en is een deel van de meetmethoden opnieuw uitgevoerd. De grondmonsters zijn na analyse gekoeld opgeslagen, en in het najaar van 2022 aangeleverd voor analyse met sensoren. Daar zijn de grondmonsters gedroogd, gezeefd en gescand voor analyse.

In Tabel 1 wordt een overzicht gegeven van de uitgevoerde meetmethoden.

Tabel 1. Gemeten bodemkenmerken in Bedrijvennetwerk Bodemmetingen (voor details, zie de Haan et al., 2021).

Parameter	Meetmethode(n)	Eenheid	BLN*
POX-C	Oxidatie in permanganaat	mg kg ⁻¹	K
Hot Water Carbon (HWC)	Extractie in heet water	mg kg ⁻¹	K
Organische stof	Gloeiverlies (met of zonder kleicorrectie)	%	K – A
Organische koolstof	Kurmies, NIRS of Rock Eval (pyrolyse)	%	K – A
I - en R - index	Rock Eval methode	-	-
CEC	Extractie in Cohex	mmol+ kg ⁻¹	K – A
pH	Extractie in CaCl ₂	-	-
N-gehalte	Hassink-methode	g kg ⁻¹	K – A
CN-ratio	Berekend	-	K – A
P-water	Extractie in water	mg P ₂ O ₅ L ⁻¹	K
P-CaCl ₂	Extractie in CaCl ₂	mg P kg ⁻¹	K
P-AL	Extractie in ammoniumlactaat-azijnzuur	mg P ₂ O ₅ 100 g ⁻¹	K
K - voorraad	Extractie in HCL en oxaalzuur	mmol+ kg ⁻¹	K – A
PMN	Anaerobe incubatie	mg kg ⁻¹	K – A
Ergosterol	Klassieke methode	-	K
PLFA	PLFA methode	-	K
Bacteriebiomassa	Microscopie	-	K
Schimmelbiomassa	Microscopie	-	K
Afbraaksnelheid	Respiratieproef	% jaar ⁻¹	-
Microrespiratie	Microresp. methode	ug C g ⁻¹ h ⁻¹	-
N-mineralisatie	Aerobe incubatieproef	mg kg ⁻¹	-
Textuur	Pipetmethode	%	K – A
Bulkdichtheid	Massa na drogen / dichtheidssensor	g cm ⁻³	K – A
Watervasthoudend vermogen, pF	Zandbak / drukpan	%	K
Aggregaatstabiliteit	Natte zeefmethode	%	K

* K staat voor Klassieke meting en A verwijst naar een Alternatieve methode, veelal gemeten via NIR-spectroscopie.

2.2 Sensoren

Voor dit onderzoek is gebruik gemaakt van twee sensorsystemen: de Handheld scanner (HH) en de LabInABox (LIAB) van AgroCares. De Handheld scanner maakt daarbij gebruik van het nabij-infrarood (NIR, near-infrared) spectrum terwijl de LIAB gebruikt maakt van een gecombineerde XRF (röntgen diffractie fluorescentie) en mid-infrarood (MIR, mid-infrared) scanner.

Sensoren voor nabij-infrarood (750-1400/2500 nm) en mid-infrarood (2500-25000 nm) licht meten de reflectie en dus absorptie van licht wat op een oppervlakte valt. In de bodem gaat het hierbij om kwarts, kleimineralen, organische verbindingen en andere mineralen. NIR- en MIR-sensoren worden in de praktijk veel toegepast, zowel voor gewasanalyses als bodemanalyses. De betrouwbaarheid van deze sensoren is sterk afhankelijk van de kwaliteit en de spectrale resolutie van de gebruikte sensoren, de juiste verwerkingsmethode en de onderliggende statistische modellen om het lichtspectrum te koppelen aan gemeten bodemeigenschappen. De onderliggende modellen zijn getraind op meer dan 25.000 bodemanalyses wereldwijd, daarbij gebruik makend van de laatste inzichten vanuit deep learning modellen. Op basis van de onderliggende onafhankelijke validatieset bleken beide sensoren voor alle basis bodemkenmerken (organische stof, klei, CEC, pH en stikstofvoorraden) een vergelijkbare meetfout te hebben als klassieke nat-chemische analyse in het laboratorium (de reproduceerbaarheid van de sensoren is opvraagbaar bij AgroCares). Een inhoudelijke evaluatie van de betrouwbaarheid en reproduceerbaarheid van de sensoren valt buiten de scope van deze studie.

2.3 Statistische analyse

Dit verkennend onderzoek is uitgevoerd om te onderzoeken of een deel van de benodigde bodemkenmerken benodigd voor inzicht in de kwaliteit van de landbouwbodem ook afgeleid kan worden van (mobiele) bodemsensoren. Hiervoor zijn de data allereerst getransformeerd (via een natuurlijke log-transformatie) en daarna gestandaardiseerd via de z-score, waarbij de eenheid wordt gewijzigd in het aantal eenheden standaardafwijking (SD) van de gemiddelde verwachtingswaarde. De z-score betekent een gestandaardiseerde waarde die zich met andere z-scores laat vergelijken. Een z-score gelijk aan 2, betekent dat de stochastische variabele zelf een waarde aanneemt die twee standaardafwijkingen voorbij zijn verwachtingswaarde (het gemiddelde) ligt. Omdat de gebruikte sensoren niet gekalibreerd zijn op de gegeven klassieke methoden zoals die zijn toegepast, wordt allereerst een Spearman correlatie uitgerekend, waarbij een hogere correlatiecoëfficiënt representatief is voor een sterke correlatie tussen twee variabelen. Daarnaast is via een eenvoudige lineaire regressie onderzocht of de ruimtelijke variatie in een bodemkenmerk verklaard kan worden op basis van de huidige bodemkengetallen die voorspeld worden door de sensoren. Dit is een indirecte methode om inzicht te krijgen in de potentiële inzetbaarheid van de sensoren.

Voor de interpretatie van de figuren en resultaten in dit rapport gelden een aantal belangrijke uitgangspunten:

- De resultaten kunnen niet gebruikt worden om een uitspraak te doen over de betrouwbaarheid en nauwkeurigheid van de sensoren op meetpuntniveau. Hiervoor is het aantal meetpunten te klein, en is er in de gedane analyse geen rekening gehouden met de meetfout op zowel de sensor als de klassieke metingen.
- De uitgevoerde analyse maakt gebruik van eenvoudige lineaire (en additieve) modellen, waarbij verder niet is onderzocht of niet-lineaire verbanden aanwezig zijn. Ook zijn ontbrekende meetwaarden (een deel van de metingen is maar in 1 jaar uitgevoerd) toegekend aan beide meetjaren om zo inzicht te krijgen in de verbanden tussen parameters zonder een evaluatie van de gevolgen hiervan op de meetfout.

De uitgevoerde analyse in R is toegevoegd als bijlage A.


3 Resultaten

3.1 Algemeen

Voor alle onderzochte bodemkenmerken zijn klassieke 1-op-1 figuren gemaakt om inzicht te geven in de verbanden tussen de klassiek gemeten bodemkenmerken en de voorspellingen afgeleid van de metingen van de Handheld en de LIAB-sensoren. In elke figuur is aangegeven of het verband tussen de gemeten en voorspelde bodemkenmerken significant is en op hoeveel meetpunten deze conclusie is gebaseerd. Meetpunten die meer dan 2 standaardafwijkingen ($2 \times SD$, outlier) afwijken van de meting zijn zonder verder onderzoek buiten de relatie gehouden, en worden in een aparte kleur (grijs) weergegeven. De verklaarde variantie als ook de significantie van de lineaire relatie (zonder correctie voor outliers) zijn voor alle bodemkenmerken opgenomen in bijlage B.

3.2 Organische stof kengetallen


Voor het meten van organische stof, als ook de kwaliteit ervan, zijn in het Bedrijvensnetwerk Bodemmetingen meerdere methoden toegepast. Dit omvat de klassieke gloeiverliesmethode (met of zonder kleicorrectie) als ook de hoeveelheid koolstof gemeten via een extractie met heet water (HWC, mg C kg^{-1}) en oxidatie met permanganaat (mg C kg^{-1}). Daarnaast is via een respiratieproef de potentiële afbraaksnelheid ($\mu\text{g C g}^{-1} \text{ uur}^{-1}$) gemeten en zijn via de Rock Eval methode twee indicatoren afgeleid die de kwaliteit van organische stof karakteriseren op basis van hun afbreekbaarheid. Deze worden hieronder weergegeven.



Figuur 3-1. Relatie tussen de variatie in spectra-afgeleide voorspellingen van C-POX (y-as) en gemeten C-POX (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).


Voor C-POX is er een duidelijk en significant verband tussen de gemeten en voorspelde waarde (Figuur 3-1). De onzekerheid is grotendeels kleiner dan 1 x de SD, en daarbij groter voor de LIAB dan de HH. Beide sensoren hebben potentie om ingezet te worden voor het schatten van C-POX.

Voor *Hot Water Carbon* (HWC) worden vergelijkbare resultaten gevonden (Figuur 3-2): circa 62 tot 73% van de ruimtelijke variatie in HWC kan worden verklaard via een spectra-afgeleide schatting ($P < 0.001$). De model-onzekerheid blijft binnen één keer de SD. Voor de Handheld analyse blijkt één meetpunt sterk af te wijken, waarbij een lage meting samenvalt met een hoge voorspelling.




Figuur 3-2. Relatie tussen de variatie in spectra-afgeleide voorspellingen van HWC (y-as) en gemeten HWC (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

Het organische stofgehalte laat opnieuw vergelijkbare resultaten zien (Figuur 3-3) waarbij de LIAB-spectra meer variatie verklaren dan de variatie in de HH-spectra. In beide gevallen is er een sterk significant verband, wat bevestigt dat het OS-gehalte betrouwbaar met sensoren kan worden gemonitord. Er is één afwijkend grondmonster waarbij een hoge klassieke meting niet kan worden gereproduceerd. De relaties voor totaal koolstof zijn beter (meer verklaarde variantie) dan voor organische stof, maar hangen wel samen met de gebruikte klassieke methodiek (niet weergegeven).



Figuur 3-3. Relatie tussen de variatie in spectra-afgeleide voorspellingen van het OS-gehalte (y-as) en gemeten OS-gehalte (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

Opvallend zijn de grote verschillen tussen de afgeleide indicatoren van de RockEval methode die karakteristiek zouden zijn voor de afbreekbaarheid van de organische stof in de bodem (Figuur 3-4). Bodems met een hoge I-index en lage R-index worden gekenmerkt door een hoge afbreekbaarheid, terwijl bodems met een lage I-index en hoge R-index veel stabiel organische stof bevatten. De LIAB-sensor kan de ruimtelijke variatie in beide indexen redelijk goed beschrijven: circa 86% van de variatie wordt verklaard. In tegenstelling daarmee is de informatie afgeleid uit het spectra van de HH minder informatief, waarbij de variatie in de R-index beter wordt beschreven dan de variatie in de I-index.




Figuur 3-4. Relatie tussen de variatie in spectra-afgeleide voorspellingen van het afbreekbaarheidsindicatoren berekend met de RockEval methode afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts) en de I-index (boven) en R-index (onder).

De variatie in de cumulatieve C-respiratie over 112 dagen incubatie kon met 42 tot 45% worden verklaard (niet weergegeven). De variatie tussen percelen was groot.

3.3 Chemische bodemkenmerken


Voor deze vergelijking is een selectie gemaakt van de volgende bodemkenmerken: de CEC (in $\text{mmol} + \text{kg}^{-1}$), de zuurgraad van de bodem, de CN-verhouding, het gehalte stikstof (N_{totaal} , g kg^{-1}), het gehalte fosfaat en de kaliumvoorraad ($\text{mmol} + \text{kg}^{-1}$).

Allereerst blijkt de variatie in de spectra van beide sensoren een groot deel van de ruimtelijke variatie in CEC van de onderzochte percelen te verklaren (Figuur 3-5): gemiddeld wordt 78 tot 81% van de variatie verklaard ($P < 0.001$). Voor beide sensoren zijn er twee situaties die als outlier worden beschouwd waarbij het bijna lijkt alsof beide situaties zijn omgewisseld (een hoge voorspelling gaat samen met een lage meetwaarde, en vice versa). Het sterke verband tussen de voorspelde en gemeten CEC suggereert dat sensoren inzetbaar zijn om dit bodemkenmerk nauwkeurig te kwantificeren.



Figuur 3-5. Relatie tussen de variatie in spectra-afgeleide voorspellingen van de CEC (y-as) en gemeten CEC (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).


Vergelijkbare gegevens worden zichtbaar voor de zuurgraad van de bodem (Figuur 3-6). Wel is hier zichtbaar dat de pH niet een normale verdeling heeft, maar gekenmerkt wordt door een bionomiale verdeling, die samenhangt met de ontstaansgeschiedenis en grondsoorten in Nederland. De spreiding is relatief klein en grotendeels kleiner dan 1 x de SD.



Figuur 3-6. Relatie tussen de variatie in spectra-afgeleide voorspellingen van de pH (y-as) en gemeten pH (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).


Omdat de CN-verhouding in de meeste landbouwbodems redelijk constant is, betekent een goede voorspelbaarheid van C-totaal ook dat de ruimtelijke variatie in N-totaal goed in beeld kan worden gebracht. Ook hier wordt 65 tot 87% van de variatie in de gemeten N-totaal waarde voorspeld op basis

van de informatie aanwezig in de huidige sensorvoorspellingen (Figuur 3-7). De onzekerheid van de LIAB is daarbij kleiner dan de onzekerheid in de HH.



Figuur 3-7. Relatie tussen de variatie in spectra-afgeleide voorspellingen van N-totaal (y-as) en gemeten N-totaal (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).


Ter illustratie wordt hieronder een voorbeeld gegeven voor een fosfaatgehalte. Sensoren gebaseerd op de reflectie van licht hebben overwegend moeite om fosfaat in de bodem te meten, in het bijzonder voor de hoeveelheid fosfaat in de bodemoplossing. Uit de analyse blijkt dat de variatie binnen P-AL voor 23 tot 51% kan worden verklaard met de sensoren (niet weergegeven), en voor P-CaCl₂ als ook P-water varieert dit van 48 tot 64%. Voor een grove indeling op basis van een hoge of lage fosfaattoestand zou dit in potentie mogelijk kunnen zijn.



Figuur 3-8. Relatie tussen de variatie in spectra-afgeleide voorspellingen van P-water (y-as) en gemeten P-water (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

De voorraad beschikbaar kalium aan het bodemcomplex (mmol+ kg^{-1}) wordt normaliter bepaald via een Cohex extractie. Gegeven het type landgebruik en samenhangende bemestingspraktijken is er substantiële variatie tussen de bedrijven met hoge voorraden op de kleigronden en lage voorraden op de zandgronden. Hoewel er nog substantiële variatie aanwezig is tussen de bedrijven (Figuur 3-9),

suggereert de uitgevoerde vergelijking dat de sensoren inzetbaar zijn om deze variatie in kaart te kunnen brengen. Gemiddeld wordt 61 tot 72% van de variatie verklaard.




Figuur 3-9. Relatie tussen de variatie in spectra-afgeleide voorspellingen van K-voorraad (y-as) en gemeten K-voorraad (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

3.4 Biologische bodemkenmerken

Op basis van de verzamelde meetgegevens is een vergelijking uitgevoerd voor een aantal biologische parameters. Voor het voorkomen van nematoden en wormen waren te weinig metingen beschikbaar. Hieronder worden de resultaten weergegeven voor de potentiële N-mineralisatie (PMN, mg N kg^{-1}), de Ergosterol meting, de PLFA, de hoeveelheden schimmel en bacteriebiomassa (afgeleid van de PLFA) en de hoeveelheid actinobacteria en grampositieve bacteriën.


Potentieel mineraliseerbare stikstof (PMN) is een onderdeel van de organische stikstof in de bodem dat voor een groot deel bestaat uit microbiële biomassa en dat beschikbaar is voor mineralisatie en de opname door planten. Het is een indicator voor de biologische activiteit en bodemvruchtbaarheid. Hoewel significant was het niet mogelijk om een sterk verband te vinden tussen de informatie in de spectra en de gemeten PMN (Figuur 3-10).



Figuur 3-10. Relatie tussen de variatie in spectra-afgeleide voorspellingen van PMN (y-as) en gemeten PMN (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).


Voor een deel kan dit samenvallen met de grote spreiding die aanwezig was in deze dataset, waardoor meer meetpunten nodig zijn om een goed verband te kunnen vaststellen. De voorspelling van LIAB levert daarbij een robuustere inschatting op dan die van de HH.

De hoeveelheid ergosterol is een maat voor de hoeveelheid schimmelbiomassa. De gemiddelde hoeveelheid ergosterol, een maat voor de hoeveelheid actieve schimmels, verschilt nauwelijks tussen de grondtypes, maar wel werd er een grote spreiding gevonden in een beperkt aantal percelen. Deze spreiding was niet te herleiden tot informatie in de HH-spectra, maar wel goed te voorspellen met de LIAB-sensor (Figuur 3-11). In welke mate dit voor de HH is op te lossen door uitbreiding van de meetset, is onduidelijk.




Figuur 3-11. Relatie tussen de variatie in spectra-afgeleide voorspellingen van ergosterol (y-as) en gemeten ergosterol(x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

In de literatuur werd al beschreven dat PLFAs niet alleen in staat zijn om onderscheid te maken tussen schimmels en bacteriën, maar ook tussen verschillende groepen van micro-organismen (zie de Haan et al., 2021), zoals Grampositieve en Gramnegatieve bacteriën, Actinobacteria en mycorrhiza (AMF). De totale hoeveelheid gemeten PLFAs is gemiddeld hoger in kleigrond dan in zand- en lössgrond, waarbij de ruimtelijke variatie goed in kaart gebracht kan worden met sensoren (Figuur 3-12).




Figuur 3-12. Relatie tussen de variatie in spectra-afgeleide voorspellingen van PLFA (y-as) en gemeten PLFA (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

Wel wordt deze vergelijking belemmerd door de aanwezigheid van grondsoort clusters. Op basis van het huidige meetnet is niet vast te stellen of deze koppeling altijd aanwezig is dan wel of het mogelijk is om hiervoor te corrigeren in de onderliggende modellen die spectra vertalen naar een meting. De variatie in bacteriebiomassa en schimmelbiomassa werd maar beperkt verklaard (Figuur 3-13), waarbij de hoeveelheid bacteriën beter samenhangt met de variatie in spectrale data dan de hoeveelheid schimmels. In welke mate dit samenhangt met het voorkomen van schimmels (de verhoudingen tussen schimmels en bacteriën lijken redelijk constant te zijn) is onduidelijk.



Figuur 3-13. Relatie tussen de variatie in spectra-afgeleide voorspellingen van de hoeveelheid schimmels (boven) en bacteriën (onder), voorspeld met sensoren (y-as) en gemeten (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

Afsluitend is nog onderzocht in welke mate de variatie in Actinobacteria en Grampositieve bacteriën samenhangt met informatie in de spectra-afgeleide voorspellingen. Beide metingen zijn redelijk goed te voorspellen: gemiddeld wordt 61 tot 82% van de variatie in het voorkomen van Actinobacteria verklaard, als ook 66 tot 68% van de variatie in Grampositieve bacteriën (Figuur 3-14). Op basis van deze kleine set aan gegevens is dat hoopgevend, en biedt het perspectief om ook sensoren door te ontwikkelen als meetinstrument voor het voorkomen van biologische bodemkenmerken. Op dit moment is de onzekerheid op een individuele meting nog te groot voor toepassing in de praktijk, al blijft de meetfout grotendeels onder 1 keer de standaarddeviatie.




Figuur 3-14. Relatie tussen de variatie in spectra-afgeleide voorspellingen van de hoeveelheid Actinobacteria (boven) en Grampositieve bacteriën (onder), voorspeld met sensoren (y-as) en gemeten (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

3.5 Fysische bodemkenmerken


Naast de besproken bodemkenmerken die samenhangen met het gehalte organische stof en de biologische en chemische functies in de bodem, spelen fysische bodemkenmerken een grote rol in het bieden van een goede structuur voor worteling en beïnvloeden ze het gedrag en transport van water en nutriënten. Binnen de dataset zijn duidelijke groepen waarneembaar (voor allerlei eigenschappen overigens) die samenhangen met het kleigehalte.

Het kleigehalte is betrouwbaar in beeld te brengen op basis van sensoren: in de huidige beperkte set kon 78 tot 82% van de variatie worden verklaard en liggen alle punten rond de 1-op-1 lijn (Figuur 3-15). Omdat niet alle grondsoorten in dezelfde mate aanwezig zijn, is het moeilijk te beoordelen of de afwijking groter of kleiner is in bijvoorbeeld löss ($n = 2$), en schieten lineaire modellen tekort in verhouding tot clusteringsalgoritmes. Desondanks laten deze resultaten zien dat sensoren inzetbaar zijn om het kleigehalte, en de daaraan gekoppelde grondsoort (relevant voor de agronomische interpretatie van meetwaarden) goed is te bepalen. Vergelijkbare resultaten zijn zichtbaar voor het gehalte aan kalk (niet weergegeven).



Figuur 3-15. Relatie tussen de variatie in spectra-afgeleide voorspellingen van kleigehalte (y-as) en gemeten kleigehalte (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

De dichtheidsmetingen laten een grote variatie zien, ook tussen de al toegepaste meetmethodieken in het veld. De bulkdichtheid, het gewicht van de bodem per volume (g cm^{-3}) is op drie verschillende manieren gemeten, door het steken van ringen, het gebruik van een guts en een bulkdichtheidsensor. De gebruikte standaardmethode is het steken van 100 cc ringen op verschillende dieptes (7,5, 15, 22,5, 30 cm-mv) die vervolgens in het lab zijn gedroogd en gewogen om de droge bulkdichtheid te bepalen. Deze methoden geven allen andersoortige informatie. De spreiding in bulkdichtheid groter is op kleigronden dan op zandgronden. Omdat de bodemdieptes varieerden, is per meetmethodiek een gemiddelde dichtheid berekend op basis van de aanwezige meetwaarden. Deze gemiddelde dichtheid is vervolgens vergeleken met de eigenschappen van de bemonsterde bovengrond, zoals deze door beide sensoren is geanalyseerd. Ter illustratie wordt hieronder een voorbeeld gegeven in relatie tot gemeten dichtheid volgens de standaard methode. Opvallend is de grote mate van spreiding als ook dat de data (zelfs na transformatie) niet normaal verdeeld is. Dit bemoeilijkt een accurate interpretatie van de statistische kenmerken.




Figuur 3-16. Relatie tussen de variatie in spectra-afgeleide voorspellingen van dichtheid (y-as) en gemeten dichtheid (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

Duidelijk is wel dat de variatie groot is, en deze variatie hangt samen met de variatie in het veld, de verschillende bodemdieptes als ook de fout op de sensor. Op basis van de huidige set is niet te herleiden waar deze ruis dan wel onzekerheid vandaan komt.


De bepaling van een pF-curve (vochtkarakteristiek) zegt iets over de textuur, structuur en de hoeveelheid organische stof van een perceel. Zandgronden hebben gemiddeld een meer horizontaal verlopende curve (minder lutum, meer grote poriën) dan kleigronden. De variatie tussen kleigronden onderling en tussen zandgronden onderling is echter groot. Het vochtgehalte bij een pF bepaling is uitgevoerd voor verschillende pF-toestanden.

In Figuur 3-17 wordt weergegeven in welke mate de variatie in gemeten vochtgehaltes bij een drukhoogte van pF0 en pF2 kan worden gemeten via sensoren. Beide sensoren laten een sterke relatie zien tussen de informatie in de spectra-afgeleide indicatoren en de gemeten vochtgehaltes. Gemiddeld kan 55 tot 70% van de variatie worden verklaard. Wel is ook hier de variatie groot over vrijwel de hele range aan meetwaarden. Dat betekent dat in de praktijk veel herhalingen nodig zijn om een betrouwbaar beeld te krijgen van de vochtkarakteristiek van percelen.



Figuur 3-17. Relatie tussen de variatie in spectra-afgeleide voorspellingen van het vochtgehalte bij verzadiging (pF0, boven) en het vochtgehalte bij veldcapaciteit (pF2, onder), voorspeld met sensoren (y-as) en gemeten (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

De stabiliteit van bodemaggregaten is een maat voor de weerstand van de bodem tegen structuurafbrekende invloeden zoals neerslag, watererosie en grondbewerking. De WSA-index geeft aan welk deel van de aggregaten onder invloed van water en een oplosmiddel stabiel blijft. Een hogere index is in principe beter. Grond met een laag percentage lutum en hoog percentage silt (zavel en löss) heeft over het algemeen een lagere structurele aggregaatstabiliteit. Vergelijkbaar met het kleigehalte is ook hier zichtbaar dat er clusters in de dataset zijn die grondsoort specifiek zijn (Figuur 3-18). Hoewel de variatie sterk samenhangt met informatie aanwezig in het spectra van de sensoren, schiet een enkelvoudige analyse van lineaire verbanden hier tekort. Wel is zichtbaar dat de verschillende grondsoorten als zodanig worden “herkend”. Aanvullende analyses zijn nodig om te kunnen onderbouwen of sensoren in staat zijn de stabiliteit van bodemaggregaten robuust te beoordelen.



Figuur 3-18. Relatie tussen de variatie in spectra-afgeleide voorspellingen van waterstabele aggregaten (WSA, y-as) en gemeten WSA (x-as), afgeleid voor de Handheld (HH, links) en de LIAB sensor (rechts).

4 Discussie en Conclusie

Op basis van twee jaren aan meetgegevens vanuit het Bedrijvennetwerk Bodemmetingen is onderzocht of het mogelijk is om de benodigde bodemkenmerken voor een analyse en beoordeling van de bodemkwaliteit via bodemsensoren in kaart te brengen. Hierbij is gebruik gemaakt van sensoren die in Nederland inzetbaar zijn, en waarmee het grootste deel van de fysische, chemische en biologische bodemkenmerken te meten is. Let wel, de gebruikte sensoren in dit onderzoek zijn niet specifiek gekalibreerd voor de geselecteerde fysische, biologische en deels ook chemische parameters. Op basis van de sensorvoorspellingen voor basis bodemkenmerken en beschikbare nutriënten is daarom via een indirecte statistische analyse onderzocht of de spectra gebruikt kunnen worden om de ruimtelijke variatie binnen het Bedrijvennetwerk Bodemmetingen te kwantificeren.

De potentiële inzet van sensoren wordt geëvalueerd in relatie tot het meten van:

- **Organische stof parameters:** het gehalte aan organische stof of koolstof, de fractie koolstof extraheerbaar met heet water (HWC) of te oxideren via permanganaat (POX-C) of via pyrolyse (inclusief de afgeleide I – en R – indexen).
- **Chemische parameters:** de CEC, de zuurgraad, en het gehalte aan fosfaat (P-water, P-CaCl₂ or P-AL) en de voorraad van beschikbaar kalium.
- **Biologische parameters:** de potentiële mineraliseerbare stikstof (PMN), PLFA, en het gehalte Ergosterol en de biomassa van bacteriën, schimmels, Actinobacteria en Grampositieve bacteriën.
- **Fysische parameters:** kleigehalte, watervasthoudend vermogen, het vochtgehalte bij pF₂, de bulkdichtheid en de hoeveelheid waterstabile aggregaten.

Voor vrijwel alle parameters is de voorzichtige conclusie dat het mogelijk is om via sensoren inzicht te geven in de ruimtelijke variatie die op kan treden als gevolg van natuurlijke omstandigheden en het gevoerde management. Deze studie is niet opgezet om de daadwerkelijke meetonzekerheid te kwantificeren; daarvoor is de dataset te klein en zijn de sensoren niet gekalibreerd. Desondanks was het mogelijk om voor het grootste deel van de BLN-metingen een betrouwbare schatting te geven: de afwijking is vrijwel nooit groter dan één keer de standaarddeviatie (SD), de verbanden zijn sterk significant, en de bias ligt gemiddeld rond de nul. Wel wordt uit deze indicatieve analyse helder dat de variatie in de voorspellingen kleiner is dan in de observaties, een resultaat van de toegepaste lineaire statistische model waarbij meetpunten die meer dan 2x de SD afwijken van het gemiddelde vaak worden overschat (bij hoge waarden) of worden onderschat (bij lage waarden). Bij daadwerkelijke toepassing van *machine learning* modellen op grotere datasets om de gemeten waarde te voorspellen is het risico hierop kleiner. Deze analyse suggereert dat sensorleveranciers met een beperkte uitbreiding van hun kalibratieset, en gekoppeld aan *deep learning* modellen die ook in staat zijn om niet-lineaire patronen te verdisconteren, het mogelijk kunnen maken om het grootste deel van de BLN-metingen betrouwbaar, robuust en goedkoop te meten.

Hoewel een daadwerkelijke kalibratie en validatie niet is uitgevoerd, blijkt uit deze indicatieve analyse dat met name variabelen gerelateerd aan het organische stofgehalte of kleigehalte van de bodem goed te correleren met de informatie zoals die op dit moment uit de spectra wordt gehaald. Sensoren voor

zichtbaar (300-750 nm), nabij-infrarood (NIR, 750-1400/2500 nm) en mid-infrarood (MIR, 2500-25000 nm) licht meten de reflectie en dus absorptie van licht wat op een oppervlakte valt. In de bodem zullen dit kwarts, veldspaten, organische verbindingen en andere mineralen zijn. Wanneer deze elementen voldoende onderscheidend zijn in het resulterende spectrale signaal kunnen deze via sensoren worden gemeten. Eerdere onderzoeken hebben laten zien dat dit vaak mogelijk is voor organische stof (en gerelateerde eigenschappen), kleigehalte, kalk, en ijzeroxiden. Dit beeld wordt bevestigd door de hier gedane indicatieve analyse: de top-20 bodemparameters die goed voorspelbaar zijn, zijn vrijwel allemaal gerelateerd aan organische stof, totaal stikstof, totaal zwavel, kleigehalte, CEC, en kalkgehalte. Als de gebruikte dataset groot genoeg is, is het vaak ook mogelijk om uitspraken te doen over pH, voorraden van nutriënten (gebonden aan de CEC of aan oxiden) en bodemstructuur. Variabelen die moeilijk te voorspellen zijn, zijn de hoeveelheid plant beschikbare nutriënten in de bodemlossing (voor o.a. N, P, K, en S), en de hoeveelheid fosfaat (dat heel sterk afhankelijk is van het gevoerde management).

De betrouwbaarheid van sensoren die gebruik maken van licht reflectie is sterk afhankelijk van de kwaliteit en spectrale resolutie van de gebruikte sensor, de grootte van de gebruikte dataset, de juiste statistische verwerkingsmethoden, en betrouwbare klassieke bodemanalyses die gebruikt worden als referentiemethode.

Omdat de ruimtelijke variatie in het veld substantieel kan zijn, hebben sensoren naast de lage kosten een aanvullend voordeel boven klassieke metingen. Sensoren worden gekenmerkt door een hoge precisie, wat betekent dat bij herhaalde metingen de fout erg klein is. Binnen het veld kunnen daarnaast meerdere metingen worden uitgevoerd, waardoor het mogelijk is om een robuuste schatting te krijgen van het gemiddelde per perceel. Uiteraard is dit zeer sterk afhankelijk van de kwaliteit van de onderliggende database waarop de sensoren zijn gekalibreerd als ook de gebruikte kalibratiemethode. De conclusies uit dit rapport zijn daarom niet generiek toepasbaar op alle beschikbare sensoren in Nederland.

In conclusie: sensoren bieden veel potentie om bodemkenmerken voor de BLN meetbaar te maken. Omdat de klassieke basisbodemkenmerken al betrouwbaar gemeten kunnen worden via bestaande sensoren (zoals de HH en de LIAB), en voortbouwend op de analyse uit dit rapport, lijkt het ons zinvol om meer bodem-biologische parameters als ook indicatoren die inzicht geven in de afbreekbaarheid van de organische stof toe te voegen aan de referentiedatabase zodat de gebruikte sensoren ook hiervoor een voorspelling kunnen genereren. Hiermee kan de toepasbaarheid en integraliteit van de BLN worden vergroot.

Literatuur

- Bonfante A et al.** (2020) Targeting the soil quality and soil health concepts when aiming for the United Nations Sustainable Development Goals and the EU Green Deal. *SOIL* 6, 453-466.
- Bünemann EK, Bongiorno G, et al.** (2018). *Soil quality—A critical review*. Soil biology and biochemistry, 120, 105-125.
- De Haan JJ, Korthals GW, et al.** (2021). Bodemkwaliteitsmetingen 2019 in Bedrijvennetwerk Bodemmetingen. Eerste analyse van de meetresultaten 2019 van integrale bodemkwaliteit op 16 akkerbouwbedrijven. Wageningen Research, Rapport WPR-888, 106 pp.
- De Haan JJ, Van den Elsen E, & Visser SM** (2021). Evaluatie van de Bodemindicatoren voor Landbouwgronden in Nederland (BLN), versie 1.0; BLN, versie 1.1 en de schets van een ontwikkelpad naar een BLN, versie 2.0. WPR-rapport 883, 54 pp.
- De Vries W et al.** (2021). Spatially explicit boundaries for agricultural nitrogen inputs in the European Union to meet air and water quality targets. *Science of the Total Environment* 786: 147283.
- Gomes A & P Reidsma** (2021). Time to Transition: Barriers and Opportunities to Farmer Adoption of Soil GHG Mitigation Practices in Dutch Agriculture. *Frontiers in Sustainable Food Systems* 5: 706113.
- Hanegraaf MC, Waghdhare VS, Van der Draai H, De Haas MJG & DW Bussink** (2012) *Verkenning van bodemsensoren voor de landbouw*. Interreg project BodemBreed, 93 pp.
- Hanegraaf MC, Van den Elsen E, De Haan J & S Visser** (2019). Bodemkwaliteitsbeoordeling van landbouwgronden in Nederland - indicatorset en systematiek, versie 1.0. WPR-rapport 795, 18 pp.
- Kempenaar C, Van Dijk C, Van Egmond F, Goldback F, Polder G & A Pronk** (2018) *Sensoren en gewasmodellen voor precisielandbouw; literatuuronderzoek DISAC deelproject E-pieper*. WPR-rapport 758, 46 pp.
- Kool F, Kempenaar C, Riepma J & A Medema** (2022) Vergelijkingsproef bodemvochtsensoren; vergelijking van verschillende bodemvochtsensoren op twee praktijkpercelen in het kader van NPPL. WPR-rapport 1129, 48 pp.
- Postma R** (2023) Mogelijkheden van toepassing van precisiebemesting. CBAV-notitie, 13 pp.
- Ratnadass A et al.** (2012). Plant species diversity for sustainable management of crop pests and diseases in agroecosystems: A review. *Agronomy for Sustainable Development* 32: 273-303.
- Riechelman WH, Van den Dool KCH, Molendijk LPG, de Haan JJ & GH Ros** (2021) *QuickScan bodeminstrumenten en datasystemen: Een analyse van tools om bodemkwaliteit integraal te beoordelen*. Nutriënten Management Instituut BV, Wageningen, Rapport 1819.N.20, 39 pp.
- Rinot O, Levy GJ, Steinberger Y, Svoray T & G Eshel** (2019). *Soil health assessment: A critical review of current methodologies and a proposed new approach*. *Science of the Total Environment*, 648, 1484-1491.
- RLI** (2020). *De Bodem bereikt?!* Digitale uitgave, Publicatie Rli 2020/02.
- Ros GH, Verweij SE, Janssen SJC, De Haan J, & Y Fujita** (2022). *An Open Soil Health Assessment Framework Facilitating Sustainable Soil Management*. *Environmental Science & Technology* 56, 17375-17384.
- TCB, Technische Commissie Bodem** (2016). Advies Toestand en dynamiek van organische stof in Nederlandse landbouwbodems. Den Haag.
- Van den Akker J** (2019) *Bodemverdichting: ondergrond en bovengrond*. Fact finding paper voor het RLI-rapport.
- Van den Elsen E, Van Tol – Leenders D, Teuling K, Römkens P, De Haan J, Korthals G & A Reijneveld** (2020). De staat van de Nederlandse landbouwbodems in 2018. Op basis van beschikbare landsdekkende dataset (C-NL) en bodem-indicatorenlijst (BLN). WEnR-rapport 3048, 100 pp.

Bijlage A. Statistische analyse

Ter illustratie wordt hieronder de R-code weergegeven voor de analyse van de bodemkenmerken gerelateerd aan het organische stofgehalte en de kwaliteit van de organische stof. Voor de andere bodemkenmerken is een vergelijkbare aanpak gevolgd.

```
# ---- determine the relationships with SOM ----

# merge HH, LIAB with measured SOM properties
dt <- copy(d1.som)[,year:=NULL]
dt <- merge(d1,dt,by=c('field'),all=T)

# select numeric columns
cols <- colnames(dt)[!grepl('year|field|SOILTYP',colnames(dt))]

# convert all to logarithmic scale and standardize to unit variance
dt[,c(cols) := lapply(.SD,log),.SDcols = cols]
dt[,c(cols) := lapply(.SD,function(x) fifelse(is.finite(x),x,NA_real_)),.SDcols = cols]
dt[,c(cols) := lapply(.SD,function(x) as.numeric(scale(x))),.SDcols = cols]

# set missing values to the mean
dt[is.na(dt)] <- 0

# remove field and year
dt[,c('field','year'):=NULL]

# correlation matrix for Spearmans Correlation coefficient
dt.cor <- as.data.table(corr::correlate(dt,method='spearman'))

# properties to predict and the names to be printed
var.pred <- c('a_c_pox','a_c_hw','a_c_i_fr','a_c_r_fr','a_c_rt_rockeval','a_c_rt_tot','a_c_sbl','c_resp_cum')
var.pred.title <- c('C-POX','C-HW','RockEval I-index','RockEval R-index','RockEval TOC','Total C','C-
SBL','cum. C-respiratie')

# select the relevant sensor data
cols.liab <- colnames(dt)[grepl('s1_',colnames(dt))]
cols.hh <- colnames(dt)[grepl('s2_',colnames(dt))]

# make an output list to save lm output
out = pout = dbs = list()

# make a for loop to do the data analysis
for(i in 1:length(var.pred)){
```

```

dt.mod <- copy(dt)
dt.mod[, ypred := get(var.pred[i])]

# set seed
set.seed(123)
# set up repeated k-fold cross-validation
train.control <- caret::trainControl(method = 'cv', number = 5)

# train the model for the HH sensor
m1step <- caret::train(ypred ~.,
  data = dt.mod[,mget(c('ypred',cols.hh))],
  method = "leapSeq",
  na.action = na.omit,
  tuneGrid = data.frame(nvmax = 1:40),
  trControl = train.control)

# select the model coefficients for the best model, and the variable names
m1coef <- coef(m1step$finalModel, as.numeric(m1step$bestTune))
cols <- names(m1coef)[!grepl('Interc',names(m1coef))]

# predict the HH model with the selected variables
m1 <- lm(ypred~.-1,data = dt.mod[,mget(c('ypred',cols))])

# set seed
set.seed(123)

# train the model for the LIAB sensor
m2step <- caret::train(ypred ~.,
  data = dt.mod[,mget(c('ypred',cols.liab))],
  method = "leapSeq",
  na.action = na.omit,
  tuneGrid = data.frame(nvmax = 1:40),
  trControl = train.control)

# select the model coefficients for the best model, and the variable names
m2coef <- coef(m2step$finalModel, as.numeric(m2step$bestTune))
cols <- names(m2coef)[!grepl('Interc',names(m2coef))]

# predict the LIAB model with the selected variables
m2 <- lm(ypred~.-1,data = dt.mod[,mget(c('ypred',cols))])

# get summary stats
sm1 <- summary(m1)
sm2 <- summary(m2)

# save output in a list: explained variance and p-value
out[[i]] <- data.table(sensor = c('hh','liab'), parm = var.pred.title[i],
  r2 = c(round(sm1$adj.r.squared,2), round(sm2$adj.r.squared,2)),
  pval = c(pf(sm1$fstatistic[1],sm1$fstatistic[2],sm1$fstatistic[3],lower.tail = F),

```

```

        pf(sm2$fstatistic[1],sm2$fstatistic[2],sm2$fstatistic[3],lower.tail = F))
    )
# save database and get predictions
dt.mods <- copy(dt.mod)
dt.mods[,p1 := predict(m1,newdata = dt.mod)]
dt.mods[,p2 := predict(m2,newdata = dt.mod)]
dt.mods[,p1res := abs(p1-ypred)]
dt.mods[,p2res := abs(p2-ypred)]

dbs[[i]] <- copy(dt.mods)

# plot the two figures
p1 <- ggplot(data = dbs[[i]][p1res<=1.95], aes(y = p1,x=ypred)) + geom_point() + theme_bw() +
  geom_point(data = dbs[[i]][p1res>1.95],col='black',size=2,shape=21,fill='gray75')+
  xlab('gemeten') + ylab('voorspeld') +
  ggtitle(paste0('HH voorspelling van ',var.pred.title[i]))+
  geom_smooth(method='lm', fill='gray75',col='black') + ylim(-2,2) + xlim(-2,2) +
  geom_abline(slope=1,intercept=0,linetype = 2) +
  stat_poly_eq(mapping = use_label(c("adj.R2","n","p.value")),formula = y~x,
    label.y = 0.9, label.x = 0.1)
p2 <- ggplot(data = dbs[[i]][p2res<=1.95], aes(y = p2,x=ypred)) + geom_point() + theme_bw() +
  geom_point(data = dbs[[i]][p2res>1.95],col='black',size=2,shape=21,fill='gray75')+
  xlab('gemeten') + ylab('voorspeld') +
  ggtitle(paste0('LIAB voorspelling van ',var.pred.title[i]))+
  geom_smooth(method='lm', fill='gray75',col='black') + ylim(-2,2) + xlim(-2,2) +
  geom_abline(slope=1,intercept=0,linetype = 2) +
  stat_poly_eq(mapping = use_label(c("adj.R2","n","p.value")),formula = y~x,
    label.y = 0.9, label.x = 0.1)

# combine both figures
p3 <- p1 | p2

# save the duoplot
ggsave(plot = p3, filename = paste0('02 figures/',tolower(var.pred[i]),'.png'), width = 25,height = 11,
  units='cm')
}

# combine output in one table
out.som <- rbindlist(out)

```

Bijlage B. Resultaten

Tabel B1. De verklaarde variantie (R2) en significantie (P-waarde) van de relaties tussen gemeten bodemparameters en de geschatte bodemparameters op basis van sensor output van de Handheld sensor (HH) of de LIAB.

Parameter	R2 HH	R2 LIAB	P-waarde HH	P-waarde LIAB
C-POX	0,83	0,59	P < 0.001	P < 0.001
C-HW	0,62	0,73	P < 0.001	P < 0.001
OS-gehalte	0,62	0,83	P < 0.001	P < 0.001
RockEval I-index	0,08	0,66	P = 0.015	P < 0.001
RockEval R-index	0,62	0,86	P < 0.001	P < 0.001
RockEval TOC	0,61	0,76	P < 0.001	P < 0.001
C-SBL	0,45	0,42	P < 0.001	P < 0.001
CEC	0,78	0,81	P < 0.001	P < 0.001
pH-CaCl2	0,77	0,82	P < 0.001	P < 0.001
CN-ratio	0,65	0,87	P < 0.001	P < 0.001
N-totaal	0,65	0,87	P < 0.001	P < 0.001
N-totaal (wc)	0,65	0,87	P < 0.001	P < 0.001
P-water	0,47	0,63	P < 0.001	P < 0.001
PAL	0,27	0,41	P < 0.001	P < 0.001
K-voorraad	0,57	0,46	P < 0.001	P < 0.001
K-voorraad (wc)	0,61	0,72	P < 0.001	P < 0.001
a_n_pmn	0,21	0,58	P < 0.001	P < 0.001
N-PMN	0,23	0,24	P < 0.001	P < 0.001
a_ergosterol	0,13	0,73	P < 0.05	P < 0.001
a_plfa	0,66	0,77	P < 0.001	P < 0.001
a_fungi_pfla	0,18	0,35	P < 0.01	P < 0.001
a_bact_pfla	0,52	0,61	P < 0.01	P < 0.001
a_bact_actino	0,61	0,82	P < 0.001	P < 0.001

a_bact_post	0,68	0,66	P < 0.001	P < 0.001
a_amf_plfa	0,23	0,48	P < 0.001	P < 0.001
Kleigehalte	0,60	0,58	P < 0.001	P < 0.001
Kleigehalte (wc)	0,78	0,82	P < 0.001	P < 0.001
Dichtheid	0,31	0,45	P < 0.001	P < 0.001
pF0	0,43	0,53	P < 0.001	P < 0.001
pF1.5	0,42	0,52	P < 0.001	P < 0.001
pF2.0	0,48	0,41	P < 0.001	P < 0.001
vochtgehalte (pF0)	0,61	0,55	P < 0.001	P < 0.001
vochtgehalte (pF2)	0,70	0,64	P < 0.001	P < 0.001
vochtgehalte (pF1.5)	0,67	0,81	P < 0.001	P < 0.001
WSA	0,43	0,60	P < 0.001	P < 0.001
Ca-voorraad	0,71	0,57	P < 0.001	P < 0.001
K-beschikbaar	0,46	0,29	P < 0.001	P < 0.001
Koolzure kalk	0,62	0,76	P < 0.001	P < 0.001
Mg-beschikbaar	0,47	0,62	P < 0.001	P < 0.001
Mg-voorraad	0,55	0,72	P < 0.001	P < 0.001
Na-beschikbaar	0,34	0,37	P < 0.001	P < 0.001
P-beschikbaar	0,43	0,5	P < 0.001	P < 0.001
S-totaal	0,9	0,82	P < 0.001	P < 0.001
Total C	0,62	0,76	P < 0.001	P < 0.001



Nutriënten Management Instituut BV
Nieuwe Kanaal 7c
6709 PA Wageningen

tel: (06) 29 03 71 03
e-mail: nmi@nmi-agro.nl
website: www.nmi-agro.nl