

# Schlussbericht

## zum Vorhaben

Thema:

**Sensor- und modellgestützte Quantifizierung von N-Bedarf und N-Angebot zur Steigerung der N-Effizienz im Maisanbau**

Zuwendungsempfänger:

**Teilvorhaben 1: Modellgestützte Analyse der N-Effizienz im Maisanbau durch Verbesserung der Ertragsprognose unter Zuhilfenahme spektraler Daten, Christian-Albrechts-Universität zu Kiel, Institut für Pflanzenbau und Pflanzenzüchtung, Abteilung Acker- und Pflanzenbau**

**Teilvorhaben 2: Bestimmung der Standort- und vorfruchtspezifischen N-Nettomineralisation durch Nutzung spektraler Informationen zur Düngungsoptimierung im Maisanbau, Georg-August-Universität Göttingen, Department für Nutzpflanzenwissenschaften, Graslandwissenschaft**

**Teilvorhaben 3: Bestimmung genotypbedingter Variabilität der kritischen N-Funktion und Ableitung der optimalen N-Düngung im Maisanbau, Landesbetrieb Landwirtschaft Hessen, Fachinformation Pflanzenbau**

Förderkennzeichen:

**Teilvorhaben 1: 2220NR112A**

**Teilvorhaben 2: 2220NR112B**

**Teilvorhaben 3: 2220NR112C**

Laufzeit:

**01.04.2021 bis 31.12.2024**

Monat der Erstellung:

**03/2025**

Gefördert durch:



**Bundesministerium  
für Ernährung  
und Landwirtschaft**

**aufgrund eines Beschlusses  
des Deutschen Bundestages**

Das diesem Bericht zugrundeliegende Vorhaben wurde aufgrund eines Beschlusses des Deutschen Bundestages mit Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) über die Fachagentur Nachwachsende Rohstoffe e.V. (FNR) als Projektträger des BMEL für das Förderprogramm Nachwachsende Rohstoffe unterstützt. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorenschaft.



# Inhaltsverzeichnis

<b>I. Kurzbericht</b> .....	<b>3</b>
1. Aufgabenstellung.....	3
2. Planung und Ablauf des Vorhabens.....	4
3. Resümee der wesentlichen Ergebnisse.....	4
a) Arbeitspakete und Meilensteine .....	4
b) Zusammenfassung .....	6
<b>II. Ausführliche Darstellung der Ergebnisse</b> .....	<b>7</b>
1. Erzielte Ergebnisse .....	7
Arbeitspaket 0: Projektkoordination/ Öffentlichkeitsarbeit.....	7
Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais .....	8
Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais .....	30
Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation .....	35
Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation.....	47
Arbeitspaket 5: Modellgestützte Analyse, Entwicklung einer optimierten N-Strategie .....	57
<b>Literaturverzeichnis</b> .....	<b>64</b>
2. Verwertung .....	75
a) Erfindungen/Schutzrechtsanmeldungen.....	75
b) Wirtschaftliche Erfolgsaussichten nach Projektende.....	75
c) Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende.....	75
d) Wissenschaftliche und wirtschaftliche Anschlussfähigkeit .....	75
3. Erkenntnisse von Dritten .....	75
4. Veröffentlichungen .....	75
<b>ANHANG</b> .....	<b>77</b>
Teilvorhaben 1: Modellgestützte Analyse der N-Effizienz im Maisanbau durch Verbesserung der Ertragsprognose unter Zuhilfenahme spektraler Daten, Christian-Albrechts-Universität zu Kiel, Institut für Pflanzenbau und Pflanzenzüchtung, Abteilung Acker- und Pflanzenbau.....	77
1. Ziel und Gegenstand des Teilvorhabens .....	77
2. Bearbeitete Arbeitspakete.....	77
Arbeitspaket 0: Projektkoordination/ Öffentlichkeitsarbeit .....	77
Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais .....	77
Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais .....	78
Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation .....	78
Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation .....	78
Arbeitspaket 5: Modellgestützte Analyse, Entwicklung einer optimierten N-Strategie .....	78
3. Wesentliche Ergebnisse des Teilvorhabens.....	78
Teilvorhaben 2: Bestimmung der Standort- und vorfruchtspezifischen N-Nettomineralisation durch Nutzung spektraler Informationen zur Düngungsoptimierung im Maisanbau, Georg-August-Universität Göttingen, Department für Nutzpflanzenwissenschaften, Graslandwissenschaft .....	79
1. Ziel und Gegenstand des Teilvorhabens .....	79
2. Bearbeitete Arbeitspakete.....	79
Arbeitspaket 0: Projektkoordination .....	79
Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais .....	79

Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais .....	79
Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation .....	80
Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation.....	80
3. Wesentliche Ergebnisse des Teilvorhabens .....	80
Teilvorhaben 3: Bestimmung genotypbedingter Variabilität der kritischen N-Funktion und Ableitung der optimalen N-Düngung im Maisanbau.....	
1. Ziel und Gegenstand des Teilvorhabens .....	80
2. Bearbeitete Arbeitspakete .....	81
Arbeitspaket 0: Projektkoordination .....	81
Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais .....	81
Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais .....	81
Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation .....	81
Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation.....	81
3. Wesentliche Ergebnisse des Teilvorhabens .....	81

## I. Kurzbericht

### 1. Aufgabenstellung

Übergeordnetes Ziel des Projekt NEffMais war es, zur Erhöhung der Stickstoff (N)-Nutzungseffizienz im Silomaisanbau beizutragen. Der Fokus der Arbeiten lag hierbei wird in der Erfassung, Modellierung und Prognose der Ertragsbildung und N-Dynamik im Silomaisanbau.

Datengrundlage bildeten im Rahmen dieses Projektes angelegte Feldversuche, großräumige Bodenbeprobungen und eine eigens zusammengestellte Datenbank historischer Silomais-N-Versuche. Moderne Sensorik wurde im Hinblick auf die Möglichkeit relevante Parameter zu erheben geprüft: Empirische Regressionsmodelle sollten entwickelt werden, um mittels Drohnen (UAV, *unmanned aerial vehicle*) relevante Bestandesparametern erheben zu können, und um mittels NIRS-Spektrometrie die N-Nachlieferung aus dem Boden zu bestimmen. Ebenfalls wurden mögliche genotypbedingter Unterschiede in der N-Effizienz untersucht. Regressionsmodelle zur Prognose der N-Nettomineralisation und des N-Düngeoptimums auf der Basis von Standort- und Managementparametern sollten entwickelt werden. Final war es geplant, Erkenntnisse aus Feldversuchen und empirischer Datenanalyse in einem prozessorientierte, dynamischen Pflanzenwachstums-Modelle zusammenzuführen, um den Einfluss der Jahreswitterung auf die Ertragsbildung und die N-Dynamik im Silomaisanbau zu prognostizieren und so zur Entwicklung ressourcenschonender zukunftsfähiger Maisanbausysteme darbeizutragen.

Der Silomaisanbau in Deutschland und Europa bietet ein erhebliches Potential für Verbesserungen der N-Effizienz, aufgrund seiner großen Anbaufläche (Europäische Kommission 2023) und da er in der üblichen engen Kopplung zur Tierhaltung oder Biogasproduktion eine Tendenz zur N-Überdüngung und damit einem hohen Risiko für N-Auswaschung in Verbindung gebracht wird (Heumann et al. 2013; Schröder et al. 2000; Velthof et al. 2020). Hohe Erträge erfordern jedoch gleichzeitig eine ausreichende N-Versorgung, so dass auch Unsicherheiten im Zusammenhang mit Wetterbedingungen und der N-Mineralisierung dazu führen, dass Landwirte tendenziell zu viel N ausbringen (Lemaire et al. 2008). Da N-Dünger für Silomais in der Regel vor oder zu Beginn der Wachstumsperiode ausgebracht wird, ist eine Anpassung der Düngermenge an die Wettervariabilität schwierig. Dies gilt umso mehr, da die N-Nettomineralisierung im Boden bei Silomais potenziell hoch und stark wetterabhängig ist (Heumann et al. 2013; Rose et al. 2023).

Jüngste Überarbeitungen der Düngegesetzgebung in Mitteleuropa zielen darauf ab, die N-Düngung besser an den Bedarf der Pflanzen anzupassen und Überschüsse zu reduzieren. Die aktuellen gesetzlichen Vorgaben zur N-Düngung im Silomais in Deutschland (DüV 2017) sieht vor, dass von einem N-Bedarfswert in Standort- und Management-spezifische Abschläge abgezogen werden (z.B. Vorfrucht, Humusgehalt). In anderen europäischen Ländern werden jedoch andere bzw. weitere Systemparameter berücksichtigt, beispielsweise die Witterungsbedingungen im Frühjahr. Zudem unterscheiden sich die Abschläge die bei gewissen Parameterausprägungen (z.B. Zwischenfrüchten) vorgenommen werden stark. Die neueste Novelle der deutschen Düngeverordnung (DüV 2017) die zulässigen Stickstoffmengen für einige Kulturen, wie beispielsweise Winterweizen, unter das wirtschaftlich optimale N-Düngeniveau gesenkt (Kage et al. 2022). Eine umfassende Analyse für Silomais fehlt jedoch bisher, ebenso eine Evaluation der in den verschiedenen Ländern verwendeten Management- und Standort-spezifischer Abschläge. Eine Studie zur Vorhersage der ökonomisch optimalen N-Düngung zu Körnermais (Puntel et al. 2018) deutet jedoch an, dass mit prozessorientierten Modellen bereits zur Aussaat von Mais eine Aussage über die Abweichung der jahresspezifisch optimalen von der im Mittel optimalen N-Düngung gemacht werden kann.

In einer Reihe von Kulturen werden bereits Messungen der spektralen Reflektion der Pflanzenbestände zur *in season* Optimierung der N-Versorgung eingesetzt (Heege et al. 2008). Liu et al. (2018) detektieren anhand UAV-basierter Multispektraldaten die N-Versorgung in Raps. Die Nutzung von UAVs zur Validation des N-Angebots und des N-Bedarfs zur Steigerung der N-Effizienz im Maisanbau wurde bisher nicht hinreichend untersucht. Eine derartige Möglichkeit, räumlich und zeitlich hochaufgelöste Bestandesdaten zu generieren, bietet jedoch ein großes Potential sowohl für die wissenschaftliche Forschung, sowie für die Düngeberatung. Neben der Standort- und Jahres-spezifisch variierenden N-Aufnahme von Mais könnten so auch Sorten-spezifische Unterschiede im N-Bedarf untersucht werden. In verschiedenen Regionen werden in der Beratungspraxis Sorten-spezifische optimale N-Konzentrationen zur Ertragsbildung im Silomais angenommen, belastbare Studien liegen hierfür in der Fachliteratur jedoch nicht vor.

Ein erheblicher Anteil der N-Aufnahme von Mais ist der N-Nachlieferung aus dem gedüngten organischen N und dem organischen Boden-N zuzuordnen (Heumann et al. 2013). Zur Ermittlung einer mittleren Standort- und vorfruchtspezifischen N-Nachlieferung haben Ratjen et al. (2018) auf der Grundlage einer Analyse von 411 N-Steigerungsversuchen zu Winterweizen ein empirisches statisches Regressionsmodell entwickelt. Für Mais liegt bisher keine vergleichbare Studie vor, eine ähnliche Vorgehensweise ist jedoch prinzipiell denkbar, sofern Zugang zu den Daten bisher im Bundesgebiet durchgeführter N-Steigerungsversuche erreicht werden kann. Zur Berücksichtigung von Effekten der Jahreswitterung können solche statischen Regressionsmodelle mit dynamischen Prozessmodellen kombiniert werden, die dann zur Berechnung der relativen Mineralisationsaktivität im betreffenden Jahr im Vergleich zur mittleren Mineralisationsaktivität genutzt werden.

Eine weitere vielversprechende Option zur Quantifizierung der N-Flüsse über die Saison könnten NIRS-basierte Messungen der Mineralisation bieten (Hartmann 2002).

## 2. Planung und Ablauf des Vorhabens

Anhand umfangreicher Feldversuche in zwei Jahren und an drei Standorten mit verschiedenen Maissorten und N-Stufen, evaluierte das beantragte Projekt genotypbedingte Differenzen in der N-Effizienz von Silomais (Arbeitspaket (AP) 1) sowie unterschiedliche Modelle zum UAV-basierten Bestandesmonitoring (AP 2). Die Daten dienen außerdem als Ausgangspunkt für die Erstellung einer umfangreichen Datenbank historischer Silomais-N-Versuche (AP 3). Die zunächst nur bundesweit vorgesehene Datensammlung wurden durch kostenlos zur Verfügung gestellte Daten aus anderen europäischen Ländern ergänzt. Auf Grundlage dieser Datenbank wurden empirische Regressionsmodelle zur Abschätzung der N-Nettomineralisation und des N-Düngeoptimums mittels Standort- und Witterungsparametern entwickelt. Zudem wurden die Daten aus den Feldversuchen zur Überarbeitung und Evaluierung eines prozessbasierten Pflanzenwachstums-Modells für Silomais (AP 5) verwendet. In AP 4 wurden deutschlandweit Bodenmonolithe von ackerbaulich genutzten Flächen entnommen. Darauf basierend erstellte NIRS-Spektren wurden in ihrer Aussagegüte zu verschiedenen relevanten Bodenparametern (z.B. die durch Inkubation gemessene N-Mineralisation) untersucht. In Anlehnung an AP 3 sollten so Faktoren zur Prognose der N-Mineralisation ermittelt werden.

## 3. Resümee der wesentlichen Ergebnisse

### a) Arbeitspakete und Meilensteine

Arbeitspakete (AP) (lt. Planung im Antrag)	Bearbeitungszeitraum (lt. Balkenplan im Antrag)	Zielerreichung
AP 0 Projektkoordination/ Öffentlichkeitsarbeit	04/2021 bis 12/2023	Die CAU koordinierte Projekttreffen, Versuchsaktivitäten und die Berichterstattung. Die erhobenen Felddaten wurden zusammengeführt, kontrolliert und in einem einheitlichen Format abgelegt. Pressemitteilungen wurden erstellt und Stakeholder-Workshops in Präsenz, hybrid und online durchgeführt. Ergebnisse wurden durch Vorträge und Beiträge in Zeitschriften veröffentlicht.
AP 1 Ermittlung genotypbedingter Differenzen der N- Effizienz von Silomais	04/2021 bis 12/2023	Die Feldversuche wie vorgesehen angelegt. In 2021 war die Versuchsdurchführung auf Grund Corona-bedingter Arbeitsschutzauflagen erschwert. Die Bestimmung der N-Konzentration der Pflanzenproben dauerte deutlich länger als vorgesehen, so dass die Daten erst im zweiten Quartal 2024 abschließend analysiert und an AP2, 4 und 5 übergeben werden konnten. Die Arbeiten der GAUG zum Thema Sorteneffekte wurden von der CAU unterstützt.
AP 2 Spektrale, UAV-gestützte Erfassung der N- Aufnahme von Silomais	04/2021 bis 12/2023	Verzögerungen in der Anschaffung der Sensorik und der Anstellung vom Personal führten zu einer geringeren Datengrundlage für dieses AP. Dennoch konnten Regressionsmodelle für verschiedene Bestandesparameter entwickelt werden. Durch die fehlenden Daten konnten jedoch nicht für jeden Standort bzw. jedes Versuchsjahr Bestandesparameter-Verläufe generiert werden. Zudem konnten die UAV-basierten N-Aufnahmedaten erst verspätet an AP5 weitergegeben werden.
AP 3 Regressionsmodellierung von Stickstoffdüngungs- optimum und N- Mineralisation	04/2021 bis 12/2023	Die Erstellung der Datenbank erfolgte in enger Zusammenarbeit der CAU und des LLH. Die Datenbereitstellung durch die Landesbetriebe dauert jedoch deutlich länger als vorgesehen. Hierdurch verzögerte sich die Entwicklung der Regressionsmodelle und deren Übergabe an AP5.
AP 4 NIRS gestützte Modellierung der N- Mineralisation	04/2021 bis 12/2023	Mehrere Bodenmonolithe wurden von der GAUG auf dem Versuchsgut der CAU entnommen und die entsprechenden Standort- und Management-Informationen zur Verfügung gestellt.
AP 5 Modellgestützte Analyse, Entwicklung einer optimierten N-Strategie	04/2021 bis 12/2023	Die verspätete Bereitstellung der Ergebnisse aus AP 1, 2 und 3 resultierte in Verzögerung in AP 5. Auf der Datengrundlage früherer CAU-Feldversuche und in enger Zusammenarbeit mit dem parallel zu NEffMais an der CAU laufenden RootWayS-Projekt war es dennoch möglich, das prozess-basierte Ertragsmodell für Silomais zu reparameterisieren und weiterzuentwickeln, um auch das

<b>Arbeitspakete (AP)</b> (lt. Planung im Antrag)	<b>Bearbeitungszeitraum</b> (lt. Balkenplan im Antrag)	<b>Zielerreichung</b>
		Pflanzenwachstum bei N-Mangel prognostizieren zu können.

<b>Meilensteine (M)</b> (lt. Planung im Antrag)	<b>Fälligkeit</b> (lt. Balkenplan im Antrag)	<b>Zielerreichung</b>
AP0 Kick-Off und Projekttreffen durchgeführt, Versuchsaktivitäten koordiniert	12/2024	Vollständig erreicht
AP0 Projektdatenbank angelegt	09/2021	Vollständig erreicht
AP0 Artikel/Pressemitteilungen für landw. Fachpresse erstellt	12/2024	Vollständig erreicht
AP0 2 Stakeholder-Workshops vorbereitet und durchgeführt	12/2024	Teilweise erreicht (zweiter Workshop wegen zu wenig Anmeldungen abgesagt, Ergebnisse wurden schriftlich und per online-Meetings mit den Stakeholdern diskutiert)
AP1 Versuche angelegt	03/2022	Vollständig erreicht
AP1 Probenahmen (Boden, Pflanze), Ernte abgeschlossen	12/2022	Vollständig erreicht
AP1 Probenaufbereitung und –analyse abgeschlossen; Daten an AP 5 übergeben	03/2023	Vollständig erreicht
AP1 Datenanalyse erfolgt	09/2023	Vollständig erreicht
AP1 Abschlussbericht AP1 erstellt	09/2023	Vollständig erreicht
AP2 Kalibrationsflüge AP1, Jahr 1 und Fertigstellung vorläufige Kalibration	03/2022	Teilweise erreicht (Datenerhebung unvollständig da keine Befliegungen zu Beginn der Saison beim LLH und der GAUG)
AP2 Kalibrationsflüge AP1, Jahr 2 und Fertigstellung Regressionsmodell Bestandesparameter	03/2023	Teilweise erreicht (Datenerhebung unvollständig da keine Befliegungen zu Beginn der Saison bei der GAUG, Ziel des APs wurde jedoch erreicht)
AP3 Sammlung verfügbarer Versuchsdaten und Erstellung einer Datenbank	12/2021	Vollständig erreicht (verzögert, zu 09/2023)
AP3 Datenauswertung, Berechnung Düngungsoptimum und Nettomineralisation	06/2022	Vollständig erreicht (verzögert, zu 12/2023)
AP3 Erstellung Regressionsmodell Düngungsoptimum und	12/2022	Vollständig erreicht (verzögert zu, 03/2024)

<b>Meilensteine (M)</b> <b>(lt. Planung im Antrag)</b>	<b>Fälligkeit</b> <b>(lt. Balkenplan im Antrag)</b>	<b>Zielerreichung</b>
Nettomineralisation		
AP4 Standorte Bodenprobenahme festgelegt	03/2022	Vollständig erreicht
AP4 Bodenprobenahme zur Inkubation	06/2022	Vollständig erreicht
AP4 Inkubation Boden zur Parametrisierung N-Nachlieferung	03/2023	Vollständig erreicht
AP4 Nmin-Analysen der Bodeninkubation	06/2023	Vollständig erreicht
AP4 NIRS-Messungen Bodenproben	06/2023	Vollständig erreicht
AP4 Datenanalyse	09/2023	Vollständig erreicht (verzögert zu, 12/2024)
AP4 Abschlussbericht AP4	12/2023	Vollständig erreicht (verzögert zu, 12/2024)
AP5 Evaluierung und Reparametrisierung eines Ertrags- und N-Aufnahmемodells für Silomais	09/2022	Vollständig erreicht (Ertragsmodell: verzögert, zu 03/2024, N-Aufnahmемodell: verzögert, zu 12/2024)
AP5 Methodenentwicklung und Evaluierung Prognose des N-Bedarfs zum 8-Blattstadium	12/2022	Vollständig erreicht
AP5 Integration und Evaluierung des Stickstoffmineralisationsmodells aus AP3	03/2023	Teilweise erreicht (Integration der Rückkopplung von N-Düngung auf Nettomineralisation in das Modell, jedoch nicht der anderen identifizierten Standort- und Management-Effekte)
AP5 Methodenentwicklung und Evaluierung Prognose des N-Bedarfs zum 8-Blattstadium	06/2023	Vollständig erreicht

## **b) Zusammenfassung**

Zugleich ökonomisch wie auch ökologisch nachhaltige Anbausysteme bedürfen einer engen Abstimmung der Stickstoffinputs an die jahresspezifischen Standortbedingungen. Zur Optimierung der Nährstoffeffizienz bedarf es jedoch Berechnungswerkzeuge, die im Rahmen dieses Projektes für den Silomaisanbau in Deutschland entwickelt werden sollten. Durch eine Reduktion der N-Düngung trägt das Projekt dazu bei, das Teilziel der Deutschen Nachhaltigkeitsstrategie zur Verringerung der Stickstoffüberschüsse auf landwirtschaftlich genutzten Flächen zu erreichen. Die Ergebnisse des Projektes können direkt in Systeme zur Entscheidungsunterstützung für Landwirte und Berater und somit in die Praxis einfließen. Das Projekt leistet damit einen Beitrag zur Weiterentwicklung der Strategie "Bioökonomie" des BMEL, indem es wissenschaftlich fundierte Handlungsoptionen bei der Erzeugung und Nutzung nachwachsender Ressourcen im Sinne des Grundwasser- und Klimaschutzes bewertet und somit zu einer Optimierung dieser Systeme führt.

Im Rahmen umfangreicher Feldversuche wurden die Dynamik des Bodenstickstoffs und der N-Pflanzenaufnahme verschiedener Genotypen und bei verschiedener N-Düngung mittels etablierter Beprobungsmethoden erfasst. Zudem wurde neuartige Sensorik in Ihrer Eignung diese N-Pfade effizient und damit praxis-relevant zu erfassen getestet. UAV (Drohne, engl. ‚unmanned aerial vehicle‘)-basierte Spektrolsensoren wurden als präzises und zeitsparendes Werkzeug zur Erhebung zeitlich und räumlich hochaufgelöster Bestandesdaten identifiziert.

Die N-Düngung im Silomais erfolgt sehr früh in der Saison. Voraussetzung für eine effizientere N-Nutzung ist daher ein zu Grunde liegendes Systemverständnis wie die erhobenen Daten und vorliegenden Informationen für eine möglich genaue Prognose des N-Düngeoptimums genutzt werden können. Daher wurden die in den Feldversuchen erhobenen Daten genutzt um ein prozess-basiertes Modell zur Ertragsbildung und N-Dynamik im Silomais (HUME-Maize) weiterzuentwickeln. Hierdurch wird es möglich, wesentliche Systemparameter und Prozesse in der N-Dynamik im Silomaisanbau zu identifizieren und in Kombination mit Witterungsprognosen zu prognostizieren. Es ist demnach ein wertvolles Tool um im Kontext des Klimawandels Handlungsbedarf und Anpassungsmöglichkeiten im Silomaisanbau aufzuzeigen.

Ein wesentlicher N-Input im Silomais erfolgt über die N-Mineralisation aus dem Boden. Eine hohen N-Nettomineralisation ermöglicht die Reduktion der N-Düngung ohne das N-Angebot für den Silomais zu reduzieren. Allerdings wird die Mineralisation durch diverse Parameter (Bodenfeuchte, Temperatur, Pflanzenresiduen, Bodentextur) beeinflusst, ist also zu Beginn der Saison vom Landwirt schwer abzuschätzen. Im Rahmen dieses Projektes wurde daher eine umfangreiche Silomais-Datenbank zusammengestellt, auf deren Basis Schätzmodelle zur Prognose der Nettomineralisation und des N-Düngeoptimums zum Start des Silomaisanbaujahres entwickelt wurden. Beide beinhalten sowohl Management (z.B. Vorfrucht, Zwischenfrucht) als auch Standortparameter (z.B. langjährige Niederschlagssumme in der Hauptphase des vegetativen Wachstums des Silomais). Die Modelle beschreiben die Variation des Düngeoptimums zu 30 %, die der N-Nettomineralisation zu fast 40 %. Die Betrachtung weiterer, bislang noch nicht analysierter Parameter könnte die Modelle demnach noch verbessern.

Der Effekt des als für die Nettomineralisation als bedeutsamsten identifizierten Managementfaktors, der N-Düngung, wurde in das Prozessmodell HUME-Maize integriert und das Modell basierend auf den erhobenen Felddaten sowie Daten aus früheren Feldversuchen der CAU reparameterisiert und evaluiert. Zudem wurde untersucht wie genau die optimale N-Düngung zum 8-Blattstadium prognostiziert werden kann.

Die vielfältigen Ergebnisse des Projektes wurden im Rahmen wissenschaftlicher und praxis-naher Tagungen präsentiert. Die Kalibrationen für die UAV-basierte Erfassung von Silomaisbestandesparametern wurden der Öffentlichkeit durch die Publikation in einem peer-reviewed Journal zur Verfügung gestellt. Weitere Artikel zu den Schätzmodellen für die N-Nettomineralisation und das N-Düngeoptimum sind bereits eingereicht bzw. werden zum Prozessmodell HUME-Maize und den Ergebnissen des Verbundpartners GAUG in Kürze eingereicht.

## **II. Ausführliche Darstellung der Ergebnisse**

### **1. Erzielte Ergebnisse**

#### **Arbeitspaket 0: Projektkoordination/ Öffentlichkeitsarbeit**

##### *Koordinierung der Aktivitäten der einzelnen Projektpartner*

Im Arbeitspaket Projektkoordination, welches in Federführung von der Abteilung Acker- und Pflanzenbau der Christian-Albrechts-Universität (CAU) übernommen wurde, erfolgte die Koordination des Gesamtprojektes. Dies umfasste die Organisation der Versuchsaktivitäten, der Projekttreffen, Überprüfung der Meilensteine und die Berichterstattung.

Es fanden regelmäßig Projekttreffen der drei Arbeitsgruppen statt, wobei überwiegend in Form von online-Videokonferenzen gearbeitet wurde. Projekttreffen in Präsenz fanden am 26.10.2021 am ausgelagerten Standort des Feldversuchs der Georg-August-Universität Göttingen (GAUG) in Wehnen und am 27.09.2022 am Versuchsstandort Hohenschulen der CAU statt. Zudem trafen sich alle Projektinterne im Rahmen eines Stakeholder-Workshops am 03.03.2023.

Im Rahmen der Feldversuche erfolgte an der CAU durch den Studenten Thorben Ehmcke-Kasch die erfolgreiche Anfertigung einer Masterarbeit. Zwei weiteren Studenten wurde die Datenerhebung für Ihre Masterarbeit ermöglicht. Im Rahmen seiner Bachelorarbeit hat Herr Simon Uffelmann erfolgreich mit NeffMais Feldversuchsdaten gearbeitet.

##### *Einrichtung und Pflege einer Projektdatenbank*

Das Datenmanagement erfolgt in Zusammenarbeit von CAU, GAUG und LLH, wobei für die neuen Feldversuche und die Silomais-Datenbank die Erstellung einheitlicher Datenstrukturen und das Anlegen einer Cloud-basierten Projektdatenbank der CAU unterstand.

Die Daten zu den durchgeführten Feldexperimenten wurden unterteilt nach Versuchsstandort, Jahr und Datenkategorien (Standort, Meteorologie, Bodenbeprobung (Wassergehalt, Nmin), Pflanzenbeprobung (Trockenmasse, N-Aufnahme, Pflanzenhöhe, Entwicklungsstadium)). Da nicht an allen Standorten sämtliche für die Modellierung in AP5 relevanten Witterungsparameter erfasst wurden, sind im Wetterdatensatz ergänzend auch Daten des Deutschen Wetterdienstes (DWD) enthalten. Sämtliche relevanten Management- und Standortinformationen (Vorfrucht, Düngetyp, Bodenart, etc.) sind in der Silomais-Datenbank, die im Rahmen von AP3 erstellt wurde, erfasst. Die im Rahmen von AP2 erhobenen UAV-Daten wurden an der CAU prozessiert und die spektrale Reflexion der Beprobungsstellen und der Parzellen in Shapefiles (Tabellen mit räumlicher Information) extrahiert. Mittels der in AP2 erstellten Bestandesparameter Kalibrationen wurden GAI-Werte und N-Aufnahmen berechnet und für die Modellierung in AP5 genutzt.

*Bereitstellung von Informationen über das Projekt und von Projektergebnissen für Stakeholder in Praxis und Wissenschaft*

Die Projektergebnisse wurden durch die CAU auf nationalen und internationalen wissenschaftlichen, sowie auf landwirtschaftlichen Tagungen (z.B. N-Workshop, ESA, ASA-CSA, Landwirtschaft und Wasserschutztagung der LWK Nds) vorgestellt und in entsprechenden Medien schriftlich publiziert (z.B. Bukowiecki et al. 2023, Komainda et al. 2023; Schwarz et al. 2023, Bukowiecki et al. 2024). Eine vollständige Übersicht über diese Tätigkeiten liefert Abschnitt 4. *Veröffentlichungen*.

Im Hinblick auf die Arbeit in AP3 (Zusammenstellung und Auswertung einer Silomais-Datenbank) fand am 03.03.2023 in Göttingen der Stakeholder-Workshop "Auswertungsmethoden von Stickstoffsteigerungsversuchen im Mais im Hinblick auf Düngeoptimum und N Nachlieferung" im hybrid-Modus mit über 30 Teilnehmenden verschiedener Landwirtschaftskammern und landwirtschaftlicher Forschungseinrichtungen statt. Der für den 16.01.2024 geplante zweite Workshop wurde auf Grund geringer Anmeldezahlen abgesagt. Die Ergebnisse wurden den Eingeladenen schriftlich im ersten Quartal 2024 mitgeteilt, in online-Gesprächen diskutiert und es wurde die Möglichkeit zur Mitarbeit an den entsprechenden Publikationen gegeben. Zudem wurden die Ergebnisse am 13.03.2024 auf der Landwirtschaft und Wasserschutztagung in Hannover und am 26.04.2024 auf einem online-Meeting der Norddeutschen Landwirtschaftskammern vorgestellt.

**Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais**

**Arbeitspaket 1, Teil 1: Bereitstellung von Silomaisbeständen unterschiedlicher Sorten mit differierender N-Versorgung an drei Standorten für weitere Untersuchungen**

Das Experiment in der Region Nord fand auf dem Versuchsgut Hohenschulen (54,3° N, 10,0° E) der Universität Kiel statt, im Bundesland Schleswig-Holstein, 15 km westlich von Kiel. Das Experiment in der Nordwest-Region wurde in der Nähe der Versuchsstation Wehnen (53°1' N, 8,1° E) im Bundesland Niedersachsen durchgeführt. Das Feldexperiment in der Mitte-Region wurde in der Nähe von Bad Hersfeld (50°4' N, 9°3' E) im Bundesland Hessen durchgeführt. Die Feldversuche wurden in den beiden Versuchsjahren 2021 und 2022 an allen drei Standorten wie vorgesehen angelegt. Die Standorte werden als Nord (CAU = NR), Nordwest (GAUG = NWR) und als Mittel (HEF = MR) Region bezeichnet. Versuchsfaktoren waren die Sorte (3 Sorten unterschiedlicher Reifegruppe; früh, mittelfrüh und mittelspät) und die N-Versorgung mit 6 mineralischen (0, 60, 120, 180, 240, 300 kg N/ha) und drei organischen (Gülle, Gärrest) bzw. kombinierten N-Stufen (60, 180, 60/60 kg Gesamt-N/ha), letztere jedoch nur bei der mittelfrühen Sorte. Jede Variante (Sorte x N) lag an jedem Standort in jedem Jahr in vierfacher Wiederholung vor. Tabelle 1 fasst die Standortfaktoren zusammen.

**Tabelle 1. Bodenmerkmale der experimentellen Regionen. Die Werte wurden aus Bodenproben mittels Bohrung entnommen und über beide Jahre gemittelt. Proben für die Lagerungsdichte (dB) wurden aus einem ungestörten Profilgraben entnommen. NR = Nord, NWR = Nordwest, MR = Mitte Region.**

Region	Tiefe [cm]	P [mg/kg]	K [mg/kg]	Mg [mg/kg]	pH	Sand [%]	Schluff [%]	Ton [%]	dB [g cm <sup>-3</sup> ]	Bodenty p	Vorfrucht
NR	0-30	80	113	88	6.9	59	29	12	1.5	Pseudogleyisch sandiger Lehm	<i>Hordeum vulgare – Lolium perenne</i>
	30-60	52	110	81	6.7	59	28	12	1.5		
	60-90	13	112	71	6.6	55	31	12	1.7		
NWR	0-30	83	42	51	5.3	91	6	3	1.4	Gley Podsol	<i>Secale cereale L. – Raphanus sativus var. oleiformis</i>
	30-60	56	26	54	5.6	91	5	3	1.4		
	60-90	38	24	38	5.5	93	4	2	1.3		

<b>MR</b>	0-30	226	168	107	6.1	48	39	13	1.5	Podsol Braunerde	Gräser und <i>Triticosecal</i> e
-----------	------	-----	-----	-----	-----	----	----	----	-----	---------------------	--

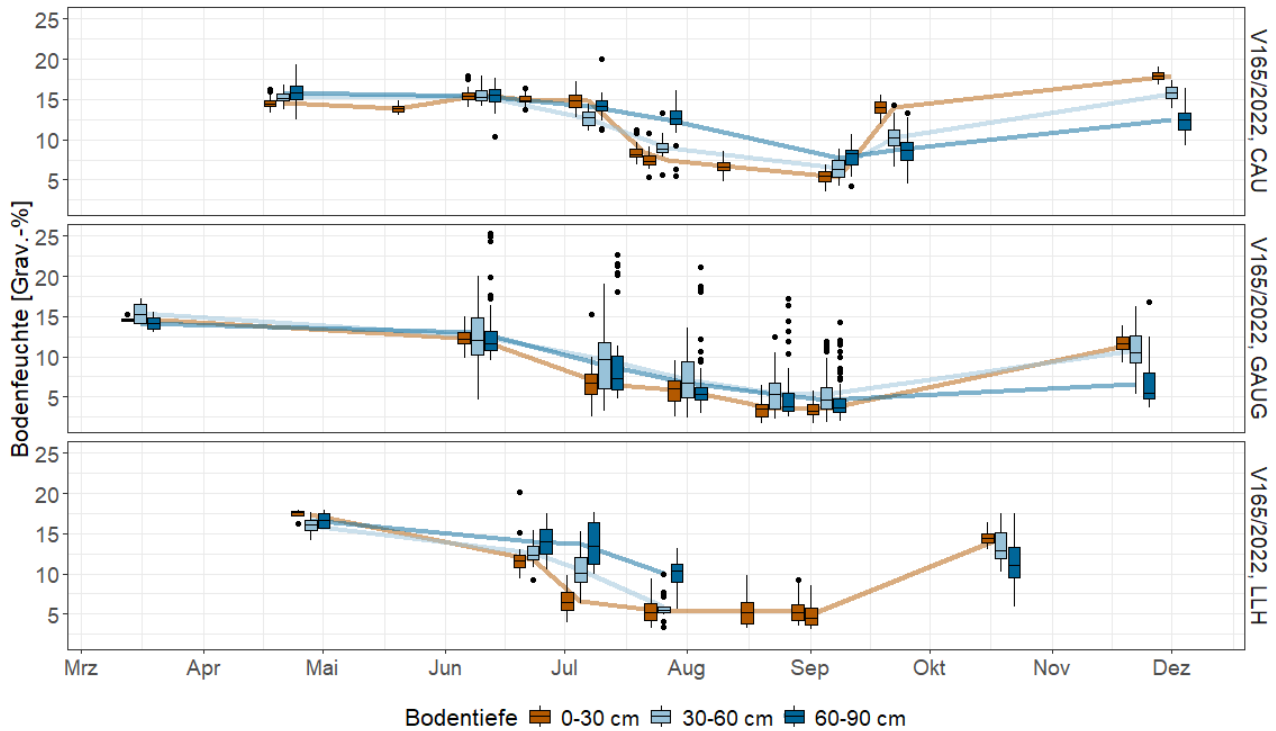
Die Versuchsdurchführung wurde jedoch auf Grund Corona-bedingter Auflagen des Arbeitsschutzes erschwert. Zudem waren die Witterungsbedingungen in den beiden Versuchsjahren schwierig: 2021 führte ein Sturm kurz vor der Ernte in MR in einem Großteil des Versuchs zu Lager (Abbildung 1a), 2022 regnete es in den Monaten nach der Aussaat beim Standort des MR und der NWR kaum.

Trotz dieser Einschränkungen wurden die drei Versuchsstandorte in jedem Jahr im Hinblick auf ihre Standorteigenschaften (Bodentextur, C/N-Verhältnis, Corg-Gehalt, Lagerungsdichte) charakterisiert. Die Dynamik der Spross-Trockenmassebildung in den beiden Jahren wurde durch Beprobung an 5-6 Terminen während der Vegetationsperiode erfasst. Am Standort der CAU wurde bei der mittelfrühen Sorte zusätzlich die Aufteilung der Trockenmasse auf die verschiedenen Pflanzenfraktionen (Blatt, Stängel, Kolben, Fahne) und die Entwicklung des Green Area Indexes (photosynthetisch aktive Fläche als Summe der Blattfläche und Stängelfläche) erfasst. Diese Arbeiten wurden in ausgewählten Varianten auch in NWR und MR durchgeführt. Sämtliche Proben wurden im Hinblick auf ihre N-Gehalte mittels NIRS und Elementaranalyse untersucht. Die Bestimmung der N-Konzentration der Pflanzenproben dauerte deutlich länger als vorgesehen, so dass die Daten erst im zweiten Quartal 2024 abschließend analysiert und an AP2, AP3 und AP5 übergeben werden konnten. Über Bodenbeprobungen wurden zusätzlich an mehreren Terminen der Bodenwassergehalt und der Boden-Nmin-Gehalt erfasst. Die Trockenheit in 2022 verhinderte die Bodenbeprobung in tieferen Schichten an einigen Terminen und ein für den Standort repräsentatives Pflanzenwachstum (Abbildung 1b). Durch die am nördlichsten Standort, dem der NR, weniger ausgeprägten Trockenheit, konnten gegenüber den anderen Standorten deutlich höhere Erträge erzielt werden. In MR-Standort, limitierten die ausbleibenden Regenfälle das Pflanzenwachstum stärker als der N-Mangel und es zeigte sich kaum eine durch die N-Düngung bedingte Ertragsreaktion.

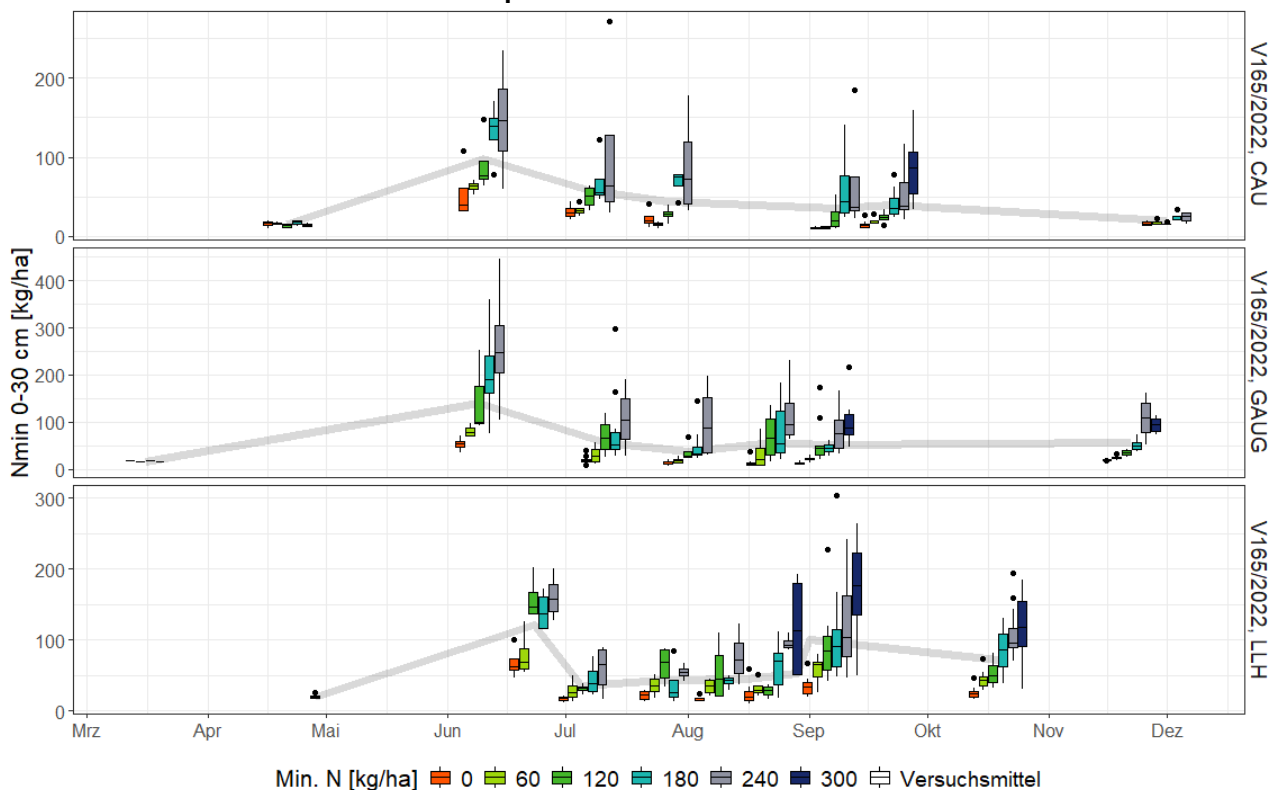


**Abbildung 1a (links): LLH-Feldversuch 2021 nach dem Sturm. Abbildung 1b (rechts): GAUG-Feldversuch 2022 kurz vor der Ernte.**

Die deutlichen Unterschiede im Wasserhaushalt zwischen den Standorten 2022 werden auch in den gravimetrischen Bodenfeuchten deutlich (Abbildung 2): in MR lag die Bodenfeuchte bei 0-30 cm Bodentiefe bereits Anfang Juli deutlich unter 10 % und damit bei etwa der Hälfte des Ausgangswertes, Ende Juli war auch die 30-60 cm-Schicht erschöpft. Im Vergleich dazu blieb die Bodenfeuchte in NR bis Juli auf dem Ausgangsniveau, war also nicht limitierend für das frühe Wachstum. Dadurch konnte der Bestand die durch die Düngung bereitgestellte N-Menge aufnehmen, wodurch zur Ernte der Nmin bei 0-30 cm im Mittel jeder Variante unter  $90 \text{ kg N}\cdot\text{ha}^{-1}$  lag (Abbildung 3). In MR lagen hingegen in der mit  $300 \text{ kg N}\cdot\text{ha}^{-1}$  gedüngten Variante zu diesem Zeitpunkt noch  $171 \text{ kg N}\cdot\text{ha}^{-1}$  vor.



**Abbildung 2: Verlauf der gravimetrischen Bodenfeuchte an den drei Versuchsstandorten in 2022. Am LLH konnten die Tiefen unter 30 cm zwischen August und Oktober auf Grund der Trockenheit und dem damit verbunden harten Boden nicht beprobt werden.**



**Abbildung 3: Nmin-Verlauf in der Bodentiefe 0-30 cm auf den drei Versuchsstandorten in 2022. Farben zeigen die unterschiedlichen mineralischen Düngungen. In hellgrau hinterlegt ist das Versuchsmittel.**

Die Darstellung der Erkenntnisse aus Arbeitspaket 1 gliedert sich in drei wesentliche Teile. Im ersten Teil wird das Konzept der kritischen N-Konzentration ( $N_{crit}$ ) anhand eines Feldversuches für drei Silomaisorten unterschiedlicher Reifegruppe validiert. Im zweiten Teil wird die N-Nutzungseffizienz (NUE) der drei in diesem Feldversuch geprüften Silomaisorten hinsichtlich der Notwendigkeit einer Anpassung der optimalen N-Düngemenge in Wechselwirkung mit Standortbedingungen geprüft. Im dritten Teil erfolgt eine Gegenüberstellung der Düngewirkung von organischer und mineralischer Düngung. Nach einem allgemeinen Einleitungs- und Methodenteil, werden die Ergebnisse der drei Teile separat dargestellt. Die dargestellten

Arbeiten in Arbeitspaket 1 befinden sich kurz vor der Einreichung zur Veröffentlichung in wissenschaftlichen Fachzeitschriften.

## Arbeitspaket 1, Teil 2: Hintergrund

Silomais (*Zea mays* L.) ist eine wichtige Kulturpflanze in gemäßigten landwirtschaftlichen Produktionssystemen und dient als Hauptquelle für qualitativ hochwertiges Futter für Nutztiere und zur Energieerzeugung. Maisproduktionssysteme sind anfällig für Nitrat-Auswaschung, wenn zuvor angewandte Stickstoff (N)-Dünger nicht ausreichend auf den Nährstoffbedarf der Pflanze abgestimmt sind (Finke et al. 1999). In dieser Hinsicht haben Svoboda et al. (2013) herausgefunden, dass die Nitrat-Auswaschung nach der Maisernte im Winter die tolerierbare Nitratgrenzwerte bei typischen N-Düngungsniveaus überschreiten kann. Laut Rudolf et al. (2021) ist die Nitrat-Auswaschung in Europa weiterhin ein Problem, und es besteht eine Übereinstimmung zwischen der Nitratbelastung des Grundwassers und der Maisproduktionsfläche, beispielsweise im Nordwesten Deutschlands (Umweltbundesamt (UBA) 2024; Deutsches Maiskomitee e.V. (DMK) 2024). Ein hohes Risiko für N-Auswaschung in der Maisproduktion resultiert häufig aus unangepasster N-Düngung (Mary 1997), was hohe Mengen an restlichem mineralischem Stickstoff (N<sub>min</sub>) nach der Maisernte verursacht (Landesämter für Düngung, 2022; 2023), was weiterhin ein praktisches Problem darstellt (Theiß und Schliephake 2020), weil es eine Ursache und ein Indikator für die Nitratbelastung des Grundwassers ist (Svoboda et al. 2013). Folglich scheint es, dass die verfügbaren Werkzeuge zur Optimierung des N-Managements in der Maisproduktion eine verstärkte Anwendung in der Praxis benötigen, um N-Verluste zu vermeiden.

Die kritische N-Konzentration (N<sub>crit</sub>) einer Pflanze ist als die minimale N-Konzentration definiert, die für ein maximales Wachstum notwendig ist (Lemaire und Gastal 1997). Der Stickstoffnährungs-Index (NNI = *Nitrogen Nutrition Index*) kann aus dem Verhältnis der N-Konzentration und N<sub>crit</sub> zu jedem Zeitpunkt während der Vegetationsperiode abgeleitet werden (Lemaire und Gastal 1997; Duru et al. 1997). Das Konzept des NNI wurde für den gesamten Maisbestand (Ciampitti et al. 2021a; Ciampitti et al. 2021b; Herrmann und Taube 2004, 2005; Plénet und Lemaire 1999) und spezifische Maisorgane (Sieling und Kage 2021) validiert und wird als über Genotypen und Umweltbedingungen hinweg gültig angenommen (Plénet und Cruz 1997). Herrmann und Taube (2005) definierten eine N<sub>crit</sub> von 10.5 g N kg<sup>-1</sup> TM für den gesamten Silomaisbestand bei Silomais-Reife als optimalen Gehalt, bei dem keine weiteren Ertragssteigerungen durch eine höhere N-Düngung zu erwarten sind. Analysen von Silomaisproben aus der Praxis in Deutschland zeigen N-Konzentrationen im Bereich von 10.8–13.9 g N kg<sup>-1</sup> TM (LUFÄ Nord 2023; Proteinmarkt 2022), was darauf hindeutet, dass die N-Düngung weiterhin überhöht ist und das N<sub>crit</sub>- und NNI-Konzept in der Anbaupraxis kaum angewendet werden.

Um das N<sub>crit</sub>-Konzept in der Praxis umzusetzen, muss der Biomasseertrag erfasst werden, was in der Regel zeitaufwendig ist, es sei denn, es werden Fernerkundungsansätze angewendet (Bukowiecki et al. 2024; Winterhalter et al. 2012). Darüber hinaus kann N<sub>crit</sub> oder NNI nicht direkt als Indikator für die Menge des angewendeten N-Düngers verwendet werden. Die Zurückhaltung bei der Umsetzung dieser Ansätze scheint zudem auf den Annahmen zu beruhen, dass genotyp-spezifische N<sub>crit</sub>-Werte erforderlich sind, da sich Genotypen in der N-Aufnahme und -Remobilisationseffizienz unterscheiden (Zhang et al. 2020) oder dass Umweltbedingungen die N-Verdünnungskurve des Mais beeinflussen könnten. Verschiedene Studien dokumentierten Unterschiede in der N-Konzentration der Pflanzen in Bezug auf Umweltbedingungen wie Bodenqualität und Wetterbedingungen (z. B. Shao et al. (2023)). Andere betonen genotyp-spezifische Unterschiede in der N-Verdünnung bei der Erstellung von Datensätzen mit sehr unterschiedlichen Genotypen, die unter verschiedenen Umweltbedingungen angebaut werden (Ciampitti et al. 2021b; Justes 1994; Makowski et al. 2020). In einer kürzlich durchgeführten Studie von Kumar et al. (2022) aus Schweden zum Effekt von sechs Maishybriden, die unter kontrastierenden Umweltbedingungen angebaut wurden, wurde eine signifikante Wechselwirkung zwischen Hybride x Umwelt bei der N-Konzentration festgestellt, was die Annahme eines hybridspezifischen Musters der N-Verdünnung unter kontrastierenden Umweltbedingungen unterstützt. Dies deutet auf genotyp-spezifische Unterschiede in der N<sub>crit</sub>-Kurve hin.

Angesichts des fortschreitenden Klimawandels wird erwartet, dass Dürreperioden in Europa häufiger und intensiver werden, was die N-Aufnahmedynamik wahrscheinlich verändern wird. So beobachteten Kunrath et al. (2020) eine geringere N-Aufnahme unter Dürrebedingungen. Ciampitti et al. (2021b) beobachteten geringe Veränderungen in der N-Verdünnung von Mais unter moderater Dürre. Der Klimawandel wird auch die Muster der Maisproduktion beeinflussen, mit längeren Wachstumsperioden im Norden und zunehmendem Dürrestress im Süden (Ergon et al. 2018; Theiß und Schliephake 2020), was Anpassungen bei Aussaatterminen und Düngestrategien erfordert. Bislang wählen Maisproduzenten ihre Hybriden anhand der Ergebnisse regionaler Sortenprüfungen aus, wobei die Reifegruppe der wichtigste Einflussfaktor auf die Auswahl ist.

Die Reifegruppe ist eines der wichtigsten Kriterien der Sortenwahl, da sie die ruminale Abbaubarkeit von Stärke beeinflusst und den Zeitraum zur Erreichung des optimalen Trockensubstanzgehalts bestimmt (Philippeau und Michalet-Doreau 1997). Die Trockensubstanz des gesamten Maisbestands ist auch wichtig, um ausreichende Silier-Eigenschaften zu erreichen (Filya 2004) und die Futterqualität für eine hohe Leistungsfähigkeit der Nutztiere zu gewährleisten (Khan et al. 2015). Spät reifende Hybriden erreichen bei

ungünstigen Umweltbedingungen nicht den erforderlichen Trockensubstanzgehalt für eine erfolgreiche Silierung. Insbesondere in Norddeutschland dominieren daher frühe oder mittel-früh reifende Maishybriden (z. B. Bukowiecki et al. (2024); Komainda et al. (2018)) und spät reifende Hybriden werden nicht verwendet (Kumar et al. 2022; Peichl et al. 2019) und sind in der Regel nicht Teil der Sortenprüfung. In Süddeutschland hingegen, wo höhere Durchschnittstemperaturen herrschen, werden später reifende Maishybriden bevorzugt, da diese im Vergleich zu früh reifenden Hybriden etwa 27% höhere Erträge erzielen (Bayerische Landesanstalt für Landwirtschaft (LfL) 2023). Zudem nehmen spät reifende Hybriden über einen längeren Zeitraum N auf, was zu geringeren Nmin-Restbeständen im Herbst führen könnte und potenziell die N-Verluste verringern kann. Mit einer Verlängerung der Wachstumsperiode im Herbst (Wittich und Liedtke 2015) werden voraussichtlich auch später reifende Hybriden in Norddeutschland angebaut. Sollte der Anbau später reifender Hybriden in Zukunft zunehmen und Dürrebedingungen wahrscheinlicher werden, bleibt die Frage offen, wie sich genotypische Effekte auf die N-Verdünnungskurve auswirken.

Um die dringende Notwendigkeit zu adressieren, die N-Verluste zu senken und hierbei Sorteneinflüsse auszuschließen, sind Untersuchungen erforderlich, um das NNI und das Ncrit-Konzept zu validieren und somit deren Anwendung in der Praxis zu steigern.

## Material und Methoden

Die klimatischen Bedingungen in den Jahren 2021 und 2022 an den drei Versuchsstandorten unterschieden sich von den langjährigen Durchschnittswerten (Tabelle 2). Während der Maiswuchsperiode 2021 lag der Niederschlag zwischen 9 und 37 % höher, während er im Jahr 2022 um 17 bis 22 % niedriger war. Zudem traten im Jahr 2022 in den Regionen Nordwest und Mitte deutlich höhere Temperaturen als üblich auf, die zusammen mit den trockenen Bedingungen zu einer schweren Dürre führten, was zu früheren als üblichen Ernteterminen in 2022 im Nordwesten und in der Mitte führte. Nur die Region Nord erlebte keine ausgeprägte Dürre, da der Niederschlag und die Temperaturen nur geringfügig variierten (Tabelle 2).

**Tabelle 2. Monatliche Niederschlagssumme (mm) (a) und mittlere Lufttemperatur (°C) (b) in 2021 und 2022 im Vergleich zur Langzeitmessung (1992-2020) vom DWD. NR = Nord, NWR = Nordwest, MR = Mitte Region.**

	Region	Jahr	Mai	Jun	Jul	Aug	Sep	Okt	Summe/ Mittel	Langzeit
a)	NR	2021	115	82	46	74	57	84	459	420
		2022	91	76	49	13	77	44	349	
	NWR	2021	89	106	89	118	84	83	569	415
		2022	54	51	47	26	114	32	325	
	MR	2021	91	87	92	88	23	35	418	368
		2022	38	8	46	42	100	61	296	
b)	NR	2021	10.5	17.7	18.8	16.3	15.3	11.1	14.9	14.7
		2022	12.7	16.0	17.3	19.2	13.5	12.5	15.2	
	NWR	2021	10.9	18.5	18.6	16.6	15.4	11.3	15.2	14.6
		2022	13.8	17.0	18.0	19.8	13.9	12.9	15.9	
	MR	2021	10.8	18.9	17.8	16.2	14.8	9.0	14.6	14.5
		2022	14.5	18.4	19.1	20.2	13.2	11.8	16.2	

## Experimentelles Design

Das Experiment hatte ein dreifaktorielles Design, das den Effekt der Maishybrid-Reifegruppe (früh, mittel-früh, mittel-spät) und der N-Düngungsmenge (sechs Stufen) untersuchte. Das experimentelle Setup war ein randomisiertes Blockdesign mit vier Replikationen und einer Parzellengröße von 6 x 12 m im Jahr 2021. Im Jahr 2022 betrug die Parzellengröße 3 x 12 m in der Region Nordwest. Für das zweite Versuchsjahr wurden die Parzellen auf einem anderen Teil in der Nähe des Feldes von 2021 angelegt. Die Maishybriden, die typischerweise in Deutschland angebaut werden, wurden gewählt, um eine Bandbreite an Reifegruppen zu repräsentieren: 'Amanova' (S210/K230, früh reifend), 'KWS Gunnario' (S250/K260, mittel-früh) und 'DS1891B' (S260/K270, mittel-spät). Alle Hybriden waren Dreibege-Maishybriden. Während S210 und S250 Intermediärtypen zwischen Flint- und Dentmais sind, ist S250 ein Flintmais.

In NR wurde Schweinegülle verwendet, in NWR Biogassubstrat und in MR Rindergülle. Der mineralische N-Dünger wurde in Mengen von 0 bis 300 kg N ha<sup>-1</sup> in gleichmäßigen Dosen aufgebracht, die in Schritten von 60 kg N ha<sup>-1</sup> erhöht wurden (nachfolgend als N0, N60, N120, N180, N240, N300 bezeichnet). Die N180-

Behandlung repräsentiert die Menge N-Dünger, die unter den vorherrschenden klimatischen Bedingungen typischerweise in der Praxis angewendet wird. Der Dünger wurde als Calcium-Ammonium-Nitrat (27 % N) vor der Saat ausgebracht und während der Saatbettvorbereitung in den Boden eingearbeitet. Im Experiment wurde zusätzlich der Effekt des N-Düngertyps (organisch vs. mineralisch) und der N-Düngermenge (0, 60, 180 kg N ha<sup>-1</sup>) geprüft. Diese Prüfung fand nur in Parzellen mit der mittelfrühen Sorte (S250) statt. Alle anderen Kulturmaßnahmen (z. B. Pflugtiefe, Phosphor- und Kaliumdüngung, Herbizide) wurden gemäß der typischen regionalen landwirtschaftlichen Praxis durchgeführt. Die Aussaat erfolgte 2021 am 10. Mai in der Nordregion, am 1. Mai in der Nordwestregion und aufgrund von langanhaltenden Niederschlägen erst am 31. Mai in der Mittelregion. Im Jahr 2022 erfolgte die Aussaat am 28. April in der Nordregion sowie am 2. Mai in den Regionen Nordwest und Mitte.

#### Datenaufnahme

Die Dynamik der oberirdischen Trockenmasse (TM)-Akkumulation wurde durch regelmäßige manuelle Entnahmen zu definierten phänologischen Stadien (ca. BBCH15, BBCH33, BBCH65, BBCH75, BBCH85) bestimmt, indem Pflanzen auf Bodenhöhe geschnitten wurden. Bei jedem Beprobungstermin wurden acht aufeinanderfolgende Pflanzen pro Reihe (zu Beginn 15 Pflanzen pro Reihe) aus den Kernreihen einer Parzelle entnommen. Nach der Bestimmung der Frischmasse (FM) jeder Pflanzenkomponente (Blätter, Stängel, Kolben) wurden repräsentative Teilproben gewogen und in Umluftöfen nur bei 60°C für 48 Stunden getrocknet, um den Trockensubstanz (TS)-Gehalt zu bestimmen. Anschließend wurden die Proben gemahlen, sodass sie durch ein 4 mm und danach durch ein 1 mm Sieb (Retsch SM 300 & Retsch ZM 300, Retsch GmbH, Haan, Deutschland) passten. Für die vorliegende Studie wurde die gesamte Pflanzenbiomasse auf Basis der getrockneten Pflanzenkomponenten berechnet. Der endgültige Biomasse-TS-Ertrag wurde zur Teigreife (BBCH 85) ermittelt, welche je nach Hybride, Region und Umweltbedingungen zwischen Ende September und Ende Oktober lag. Eine Übersicht ist in Tabelle 3 zu finden.

Zur Bestimmung der N-Konzentration wurde Nahinfrarot-Reflexionsspektroskopie (NIRS) verwendet, wobei jede Probe zweimal mit einem Phoenix 5000 (BlueSun Scientific Inc., USA) gescannt wurde. Insgesamt wurden 5273 NIRS-Messungen durchgeführt. Wir verwendeten 408 und 296 Kalibrierproben der N-Konzentration aus Laboranalysen, die 2023 bzw. 2024 mit Hilfe der Elementaranalyse (Vario el Cube, Elementar Analysensysteme GmbH, Langenselbold, Deutschland) durchgeführt wurden. Dafür wurden die Proben vor der Analyse auf 0.2 mm fein gemahlen. Infolgedessen wurde das NIRS-Ergebnis an einem Teilstichproben-Set von insgesamt 13% der Gesamtprobenzahl validiert und eine verbesserte NIRS-Kalibrierung für die N-Konzentration von vegetativem und generativem Maismaterial im Projekt entwickelt. Der Standardfehler der Kalibrierung (SEC) betrug 0.12 % N, der Standardfehler der Kreuzvalidierung (SECV) 0.2 % N und der gewichtete durchschnittliche quadratische Mittelwertfehler der Vorhersage (RMSEP) lag bei 0.14 % N.

**Tabelle 3. Übersicht der Probenahmeterminen, der Tage nach Aussaat, der Temperatursumme seit Aussaat (GDD, 8°C Basis), und der finalen Ernteterminen. NR: Nord, NWR: Nordwest, MR: Mitte**

Region	Jahr	Probenahme	1	2	3	4	5	6
NR	2021	Datum	22.06.	13.07.	10.08.	07.09.	21.09.	05.10.
		DAS	43	64	92	120	134	148
		GDD (°Cd)	287	505	785	1009	1116	1205
		BBCH	16	32	68	80	85	87
		Ernte					S210	S250/S260
	2022	Datum	08.06.	06.07.	26.07.	07.09.	20.09.	-/
		DAS	41	69	89	132	145	-/
		GDD (°Cd)	192	440	630	1083	1157	-/
		BBCH	15	31	59	83	84	-/
		Ernte					S210/S250/S260	-/
NWR	2021	Datum	23.06.	12.07.	02.08.	01.09.	28.09.	18.10.
		DAS	53	72	93	123	150	170
		GDD (°Cd)	338	537	754	1015	1222	1290
		BBCH	18	35	67	73	85	87
		Ernte					S210	S250/S260
	2022	Datum	09.06.	12.07.	02.08.	25.08.	06.09.	-/
		DAS	38	71	92	115	127	-/
		GDD (°Cd)	241	555	777	1067	1187	-/
		BBCH	16	50	67	76	85	-/

		Ernte					S210/S250/S260	-/
MR	2021	Datum	17.06.	20.07.	10.08.	08.09.	06.10.	26.10.
		DAS	17	50	71	100	128	148
		GDD (°Cd)	182	524	720	951	1125	1144
		BBCH	15	35	65	72	79	84
		Ernte					S210	S250/S260
	2022	Datum	15.06.	04.07.	25.07.	15.08.	25.08.	01.09.
		DAS	44	63	84	105	115	122
		GDD (°Cd)	325	554	791	1047	1171	1240
		BBCH	16	33	65	72	83	83
		Ernte					S210	S250/S260

Für ein tieferes Verständnis der Effekte der Hybriden auf die oberirdische Biomasseverteilung wurden die Hälfte der Pflanzen aus den N0- und N180-Behandlungen zum endgültigen Erntetermin manuell in grüne Blätter, Stängel, Kolben, Lieschblätter, Fahnen und abgestorbene Blätter sortiert. Nach der Bestimmung der FM jeder Organ-Komponente wurden repräsentative Teilproben gewogen und bei 60°C für 48 Stunden getrocknet, um den Trockensubstanzgehalt zu bestimmen. Die Berechnungen der oberirdischen Pflanzenorganverteilung folgten dem Ansatz von Zhang et al. (2020), indem das Trockengewicht jedes Organs als Anteil der gesamten oberirdischen TM an einem bestimmten Datum betrachtet wurde. Somit wurde der Anteil der Blätter (F\_leaves), der Stängel (F\_stems) und des Kolbens (F\_ear) berechnet, die zusammen durchschnittlich 89 % der oberirdischen Biomasse ausmachten.

Zur Ermittlung des Bodenmineralstickstoff-Gehaltes ( $N_{min} = NO_3-N + NH_4-N$ ) wurden nach der Maisernte mit einem mechanischen Bohrer in einer Bodentiefe von 0-90 cm Proben entnommen. Pro Parzelle wurden dreifach Proben genommen, zusammengeführt, sofort im Feld gekühlt und später bei -18°C eingefroren. Nach dem Auftauen im Labor wurden die Proben mit 0.01 mol  $CaCl_2$  extrahiert. Die  $NH_4$ - und  $NO_3$ -Gehalte wurden mit einem kontinuierlichen Flussanalysator von Seal Analytical (Modell: QuAAtro39 AutoAnalyzer) analysiert. Die  $N_{min}$ -Menge ( $kg\ ha^{-1}$ ) wurde unter Berücksichtigung des tatsächlichen Bodenwassergehalts (Trocknung bei 105 °C) und der Trockenrohddichte berechnet.

Die verfügbare mineralische N-Menge im Boden ( $N_{av}$ ,  $kg\ N\ ha^{-1}$ ) wurde wie folgt berechnet:

$$N_{av} = (N_{min\ Ernte\ N0} + N - Aufnahme\ Ernte\ N0) - N_{min\ Frühling} + mineralische\ N - Düngung \quad (1)$$

Dieser Ansatz ermöglicht es, die Menge des mineralischen N, das dem Pflanzenwachstum durch Bodenmineralisation zur Verfügung steht, zu bestimmen, basierend auf Bodenanalysen und der N-Aufnahme der Pflanzen im ungedüngten Kontrollbehandlungsbereich (N0). Durch die Berücksichtigung der N-Aufnahme im N0-Behandlungsbereich jeder Hybride x Region x Jahr können physiologische Unterschiede in der N-Akkumulationseffizienz erfasst werden. Dieser Ansatz unterscheidet sich leicht von früheren Studien (z. B. Barbieri et al. (2008), Bukowiecki et al. (Xa)), die versuchten, die Boden-N-Freisetzung zu modellieren, anstatt die Verfügbarkeit von Boden-N zu verwenden.

Die Stickstoffnutzungseffizienz ( $NUE_{DM}$ ,  $kg\ kg^{-1}\ N_{av}$ ) wurde als das Verhältnis zwischen der Erntebiomasse ( $kg\ TM\ ha^{-1}$ ) und dem verfügbaren Stickstoff ( $N_{av}$ ,  $kg\ ha^{-1}$ ) berechnet (Barbieri et al. 2008). Die Effizienz des vom Erntegut aufgenommenen Stickstoffs (d.h. physiologische Effizienz, PE,  $kg\ TM\ kg^{-1}\ N_{up}$ ) wurde als Quotient zwischen der oberirdischen Biomasse des Mais und der Stickstoffaufnahme ( $N_{up}$ ) in der oberirdischen Biomasse bei der Ernte definiert (Teixeira et al. 2014). Der Stickstoffnährstoffindex (NNI) wurde als Quotient zwischen der tatsächlichen N-Konzentration bei der Ernte und der kritischen N-Konzentration ( $N_{crit}$ ) berechnet, die für maximales Wachstum erforderlich ist (Plénet und Lemaire 1999), und berechnet sich wie folgt:

$$N_{crit} = 3.4 \times Ertrag - 0.37 \text{ für Biomasseerträge } \geq 1\ t\ DM\ ha^{-1} \quad (2)$$

#### Datenanalyse Teil 1:

Alle statistischen Analysen wurden mit R Studio Version 4.2.3 (R Core Team 2023) durchgeführt. Für die Berechnung der  $N_{crit}$ -Werte wurden nur Daten mit Werten  $> 1\ t\ TM\ ha^{-1}$  berücksichtigt, um die N-Verdünnungskurven abzuleiten (Plénet und Lemaire 1999). Ein lineares Plateau-Modell wurde für jedes Entnahmedatum, jede Region, Wiederholung und jede Hybride angepasst (Justes 1994; Sieling und Kage 2021). Das lineare Plateau-Modell erfordert keine vorherige Klassifikation von nicht-N-limitierenden gegenüber N-limitierenden Bedingungen zur Identifikation der  $N_{crit}$ -Werte (Makowski et al. 2020). Basierend auf den so abgeleiteten  $N_{crit}$ -Werten und der entsprechenden Pflanzenbiomasse wurde eine  $N_{crit}$ -Verdünnungskurve für jede Hybride in jeder Region geschätzt, indem eine negative Potenzfunktion unter Verwendung einer

nichtlinearen Beziehung im Paket ‚nlstools‘ (Baty et al. 2024) mit der folgenden Gleichung angenommen wurde:

$$\%N_{crit} = a \times W^{-b} \quad (3)$$

Dabei ist %N<sub>crit</sub> die kritische N-Konzentration (%) und W die jeweilige TM der Kultur (t ha<sup>-1</sup>). Der Koeffizient a repräsentiert die N-Konzentration (%) bei 1 t TM ha<sup>-1</sup>, und der Koeffizient b bezieht sich auf das Verhältnis der Reduktion der N-Konzentration relativ zur Wachstumsrate der Kultur. Die Funktionsparameter a und b wurden als statistisch unterschiedlich zwischen den Sorten und Regionen betrachtet, wenn die 95%-Konfidenzintervalle nicht überlappen (Ciampitti et al. 2021a; Ciampitti et al. 2021b). Der RMSE, das R<sup>2</sup> und der MAE wurden unter Verwendung des Pakets ‚modelr‘ (Wickham 2016) berechnet.

Die endgültige Pflanzenbiomasse bei der Ernte und das jeweilige NNI wurden unter Verwendung von linearen gemischten Modellen im Paket ‚nlme‘ (Pinheiro und Bates 2025) unter Berücksichtigung der festen und Wechselwirkungen von Hybride, Region und N-Düngung statistisch analysiert. Die Signifikanz der festen Effekte wurde unter Verwendung des F-Werts mit dem entsprechenden p-Wert bewertet. Der zufällige Effekt bestand aus dem Block pro Standort, der im Jahr geschachtelt war. Statt mehrfacher Vergleiche unter signifikanten Faktorstufen wurden quadratische Regressionen verwendet, um die Pflanzenbiomasse und den NNI als Funktion der N-Düngung getrennt nach Hybriden (Pflanzenbiomasse) und Regionen (Pflanzenbiomasse und NNI) zu beschreiben (Piepho und Edmondson 2018).

#### *Datenanalyse Teil 2:*

Der Erntebiomasseertrag, die Nup, die NUE<sub>DM</sub> und die PE zur Maisernte wurden unter Verwendung von linearen gemischten Modellen analysiert, wobei Jahr, Region, Hybride und N-Menge als feste Effekte und alle möglichen dreifachen Interaktionseffekte berücksichtigt wurden. Der Block wurde als zufälliger Effekt verwendet. In den Modellen für Biomasse, Nup, NUE<sub>DM</sub> und PE wurden separate Varianzen pro Region und N-Menge zugelassen, um die Anforderungen einer Normalverteilung und Homoskedastizität nach visuell bestimmter Überprüfung mittels Quantil-Quantil-Diagrammen zu erfüllen. Die N-Menge wurde in dieser Analyse als qualitative Variable verwendet. Mittelwertvergleiche wurden post-hoc mit dem Tukey HSD-Test im Paket ‚emmeans‘ (Lenth und Lenth 2018) für alle Haupteffekte und Interaktionen durchgeführt, die nicht durch die N-Menge beeinflusst wurden. In Fällen, in denen die N-Menge einen signifikanten Haupteffekt hatte oder in Wechselwirkung mit anderen Faktoren stand, wurden quadratische Modelle für signifikante Wechselwirkungen implementiert, wobei die N-Menge als quantitative Variable verwendet wurde, wie von Piepho und Edmondson (2018) empfohlen. Danach wurden Vergleiche der linearen Steigungen mit der Funktion `emtrends()` durchgeführt, um die N-Wirkungen zwischen Hybriden oder Regionen zu analysieren. Die NUE<sub>DM</sub> und PE wurden miteinander korreliert, um Trade-offs zwischen den N-Effizienzparametern zu erkennen, wobei robuste Korrelationen im Paket ‚WRS2‘ (Mair et al., 2024) verwendet wurden. Ein  $\alpha$ -Niveau von  $p < 0.05$  wurde als signifikant und ein  $\alpha$ -Niveau von  $p < 0.1$  als marginal signifikant (Ganesh und Cave 2018) betrachtet.

#### *Datenanalyse Teil 3:*

Der gesamte Trockensubstanzgehalt bei der Ernte wurde als arithmetischer Mittelwert  $\pm$  Standardabweichung untersucht. Der Ertrag der Pflanzenbiomasse, Nup, PE und NNI bei der Maisernte sowie die Boden-N<sub>min</sub>-Mengen bei BBCH13 (N<sub>min\_start</sub>) und zum Ende der Vegetationsperiode (N<sub>min\_end</sub>) wurden mit linearen gemischten Effekten-Modellen analysiert, wobei Jahr, Region und Behandlung als feste Effekte und alle möglichen Interaktionseffekte berücksichtigt wurden. Die Behandlung kombiniert sowohl Düngermenge wie auch Düngertyp (N0, N60 organisch, N60 mineralisch, N180 organisch, N180 mineralisch). Der Block diente als zufälliger Effekt. Die Anforderungen an eine Normalverteilung und Homoskedastizität wurden visuell mit Quantil-Quantil-Diagrammen überprüft. Separate Varianzen wurden in den Modellen für die N<sub>min</sub>-Mengen bei BBCH13 und zum Ende der Vegetationsperiode zugelassen um Heteroskedastizität zu vermeiden. Im Modell von N<sub>min\_end</sub> wurde die Analyse auf einer Quadratwurzel-transformierten Skala durchgeführt, um die Normalität der Residuen zu verbessern. Ein Ausreißer musste aus dem Datensatz der PE entfernt werden. Ein Ausreißer wurde angenommen, wenn der Wert 1.5-fach außerhalb des Interquartilsbereichs der jeweiligen Zielvariable lag. Die Mittelwertvergleiche wurden post-hoc unter Verwendung des Tukey’s HSD-Tests im Paket ‚emmeans‘ (Lenth und Lenth 2018) für alle signifikanten Haupteffekte und Interaktionen durchgeführt. Ein  $\alpha$ -Niveau von  $p < 0,05$  wurde als signifikant betrachtet und ein  $\alpha$ -Niveau von  $p < 0.1$  als marginal signifikant (Ganesh und Cave 2018).

### **Datenanalyse, Teil 1: Keine Variation in den kritischen Stickstoffkurven moderner Maishybriden unterschiedlicher Reifetypen, unter variierenden Umweltbedingungen**

#### **Kurzfassung**

Silomais (*Zea mays* L.) ist eine Schlüsselpflanze im europäischen Viehzucht- und Bioenergiesektor, und die Düngung mit Stickstoff (N) ist ein wichtiger Managementfaktor im Zusammenhang mit N-Verlusten. Kritische N (N<sub>crit</sub>)-Verdünnungskurven beschreiben die Beziehung zwischen Pflanzenbiomasse und der minimalen N-Konzentration, die für maximales Wachstum erforderlich ist, und dienen als Maßstab zur Diagnose des N-

Status. Durch die fortschreitenden klimatischen Veränderungen können später reifende Sorten auch in nördlicheren Breiten angebaut werden. Daher ist es wichtig zu prüfen, ob angepasste Ncrit-Verdünnungskurven bei Anbau unterschiedlich schnell abreifender Sorten erforderlich sind, um das N-Düngungsmanagement zu verbessern. Diese Studie hatte zum Ziel, (1) mögliche Unterschiede der Ncrit-Kurven von kontrastierenden Sorten und regionalen Bedingungen zu analysieren und (2) den N-Ernährungsindex (NNI) zu berechnen. Die Datenerhebung erfolgte in einem zweijährigen Feldexperiment in drei Regionen Deutschlands, bei dem drei Maishybriden mit unterschiedlichen Reifetypen bei sechs verschiedenen mineralischen N-Düngungsstufen evaluiert wurden. Die oberirdische Trockenbiomasse (TM) der Pflanzen und die N-Konzentration der Pflanzen wurden zu fünf bis sechs Ernteterminen während des gesamten Wachstums bestimmt. Der Ertrag der Pflanzenbiomasse nahm mit der N-Düngung im Allgemeinen zu. Aufgrund von Trockenheit im Jahr 2022 kam es regional zu Abweichungen in der N-Düngewirkung. Diese zeigte aber keine Unterschiede zwischen den Sorten. Die Ncrit-Funktionsparameter und der NNI unterschieden sich nicht zwischen den Sorten und Regionen. Die abgeleiteten funktionellen Parameter der Ncrit-Verdünnungskurve waren aufgrund der besonderen Umweltbedingungen (mit Trockenheit und Feuchte) für die drei geprüften Sorten nicht von Region oder Sorte beeinflusst, wodurch Ncrit und NNI als ein generelles Instrument zur Bewertung der N-Effizienz genutzt werden kann.

## Zielstellung

Das Ziel dieser Studie war es, Ncrit-Verdünnungskurven und NNI-Werte für drei moderne Silomais-Hybriden, die sich in ihrer Reifegruppe (früh, mittel-früh, mittel-spät) unterscheiden, zu identifizieren, die über zwei Jahre mit sehr unterschiedlichen Klimabedingungen und in drei Regionen von Mittel- bis Norddeutschland angebaut wurden. Es wurde Hypothese aufgestellt, dass hybriden- oder regionenspezifische N-Verdünnungskurven erforderlich sind, um die N-Ernährung im Silomais genau zu schätzen.

## Ergebnisse

*Ncrit-Funktionen variierten leicht zwischen den Regionen und Hybriden, zeigten jedoch keine signifikanten Unterschiede*

Bei Anwendung des linearen Plateau-Ansatzes zur Ableitung der Ncrit-Funktionen wurde ein  $R^2$  von 0.83, ein RMSE von 0.23 %N und ein MAE von 0.18 %N ermittelt. Die Koeffizienten für die N-Verdünnungskurve unterschieden sich in Bezug auf die Hybriden oder Regionen (Tabelle 4). Allerdings deuten Überlappungen in den Konfidenzintervallen darauf hin, dass es keine signifikanten Unterschiede in den Koeffizienten zwischen den Hybriden oder Regionen gab, obwohl die Ncrit-Funktionen tendenziell für die S210-Hybride und in der Nordwestregion höher waren im Vergleich zu den anderen Hybriden und Regionen.

**Tabelle 4. Die Koeffizienten a und b (95% Konfidenzintervall) der N-Verdünnungsfunktion, berechnet unter Verwendung des Linear-Plateau-Ansatzes, werden hier mit den Koeffizienten verglichen, die von Plénet und Lemaire (1999) gefunden wurden, einschließlich des  $\pm$  95% Konfidenzintervalls. N = Nord, NW = Nordwest, M = Mitte.**

Hybrid	a	b	Region	a	b
<b>S210</b>	4.65 (3.76, 5.54)	0.47 (0.39, 0.56)	<b>N</b>	3.82 (3.45, 4.19)	0.34 (0.28, 0.39)
<b>S250</b>	4.32 (3.58, 5.05)	0.43 (0.35, 0.51)	<b>NW</b>	4.97 (3.49, 6.44)	0.53 (0.41, 0.66)
<b>S260</b>	3.83 (3.33, 4.33)	0.43 (0.35, 0.50)	<b>M</b>	4.54 (3.25, 5.82)	0.49 (0.38, 0.60)
<b>Plénet &amp; Lemaire (2000)</b>	3.4 (3.32, 3.48)	0.37 (0.35, 0.39)		3.4 (3.32, 3.48)	0.37 (0.35, 0.39)

Die Koeffizienten a und b, die über die Regionen und Hybriden hinweg abgeleitet wurden, betragen 4.1 (3.73, 4.46 95% CI) bzw. 0.43 (0.38, 0.46 95% CI). Diese Werte sind vergleichbar mit denen, die in früheren Studien (Plénet und Lemaire 1999) berichtet wurden, obwohl eine leichte Abweichung für Biomasseerträge unter 10 t TM ha<sup>-1</sup> festgestellt wurde (Tabelle 4, Abbildung 4).

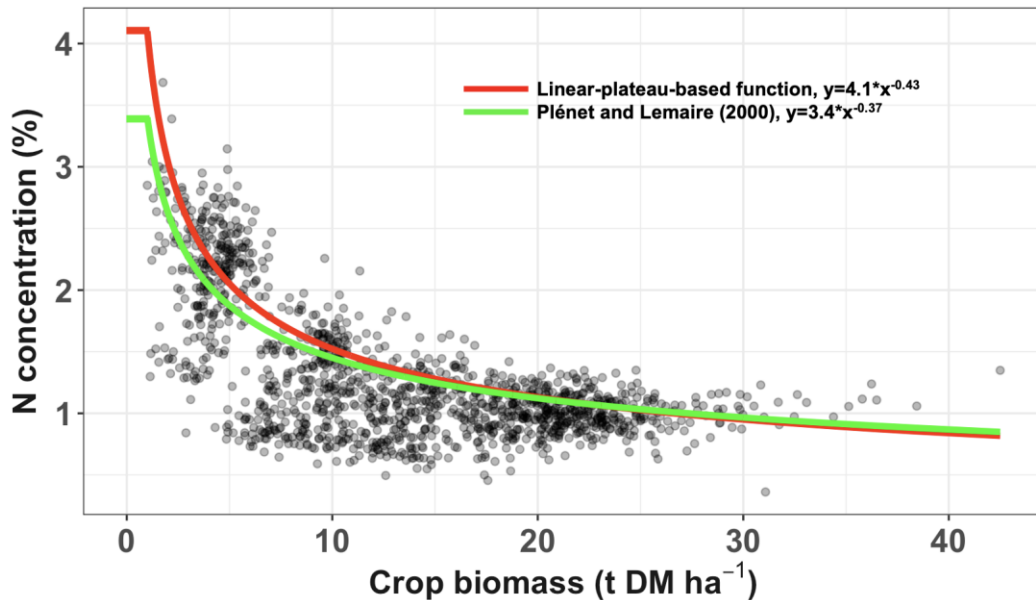


Abbildung 4. Die Beziehung zwischen der kritischen N-Konzentration (%) und der Pflanzenbiomasse für den Zeitraum zwischen 1 t TM ha<sup>-1</sup> und der Teigreife über verschiedene Regionen, Jahre und Hybriden hinweg. Gezeigt werden die kritischen Verdünnungskurven, die aus den Daten der aktuellen Studie und denjenigen von Plénet und Lemaire (1999) abgeleitet wurden.

NNI variierte je nach Region und N-Düngung, jedoch nicht je nach Hybrid

Der NNI wurde signifikant durch die Wechselwirkung von Region x N-Düngung beeinflusst ( $F_{10.367} = 5$ ,  $p < 0.001$ ), während der Faktor Hybride keinen signifikanten Einfluss hatte. Die linearen und quadratischen Reaktionen des NNI auf die N-Düngung waren signifikant (Abbildung 5). Ein NNI von 1 gilt als optimal für die N-Versorgung, während ein NNI  $> 1$  auf einen Überschuss und ein NNI  $< 1$  auf eine unzureichende N-Versorgung hinweist. Die linearen Steigungen der Region Nord unterschieden sich signifikant von denen der Regionen Nordwest und Mitte, und ein NNI  $> 1$  wurde dementsprechend mit N180 in der Nordregion erreicht. Der NNI überschritt in der Region Mitte und in der Nordwestregion niemals den Wert von 1 (Abbildung 5).

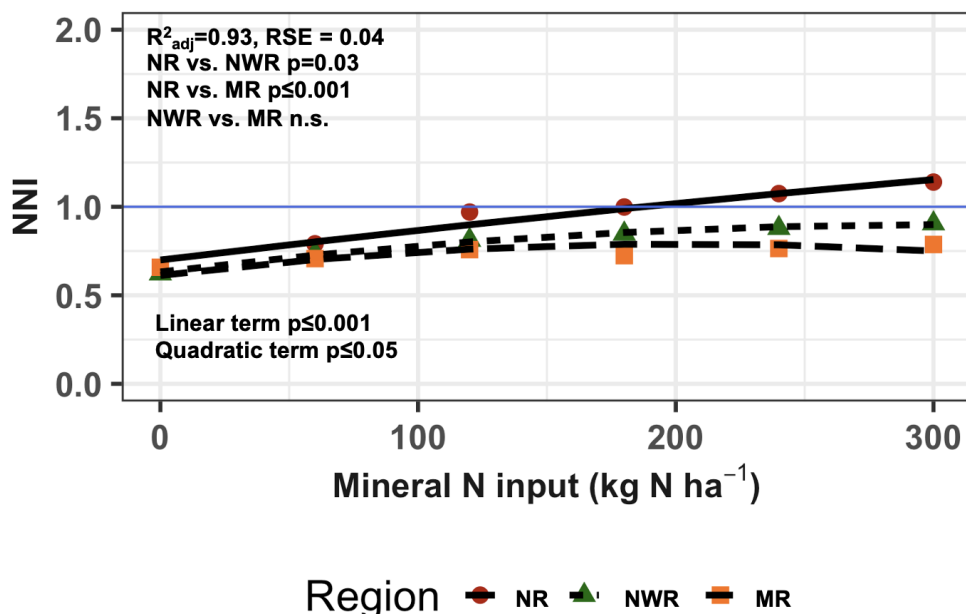
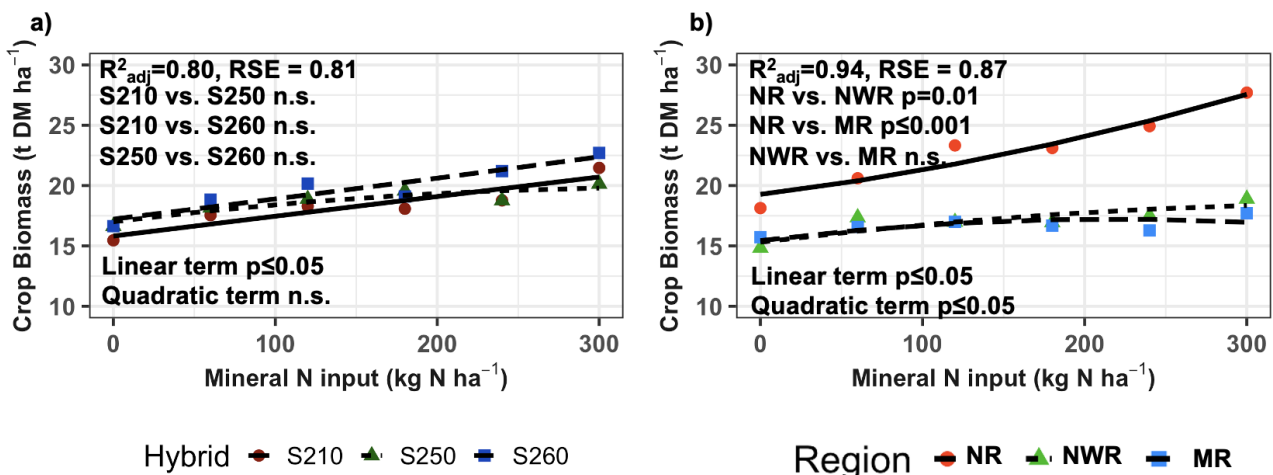


Abbildung 5. Quadratische Modelle für die Wechselwirkung Region x N-Düngung auf den Stickstoffernährungsindex (NNI). Die dargestellten Punkte sind die beobachteten arithmetischen Mittelwerte. Das  $R^2_{adj}$  bezieht sich auf das angepasste Bestimmtheitsmaß des quadratischen Modells. RSE = Residualstandardfehler. Gezeigt sind Vergleiche der linearen Steigungen zwischen den Regionen. NR = Nord, NWR = Nordwest, MR = Mitte.

Der Ertrag zur Ernte wurde durch regionale Bedingungen, jedoch nicht durch Hybriden beeinflusst

Die Erträge zur Ernte reichten von 9.1 t TM ha<sup>-1</sup> in der Region Mitte bis 29.4 t TM ha<sup>-1</sup> in der Region Nord. Die Wechselwirkungen von Hybride x N-Düngung ( $F_{10.368} = 1.9$ ,  $p = 0.038$ ) und Region x N-Düngung ( $F_{10.368} = 3.5$ ,  $p = 0.0002$ ) waren signifikant (Abbildung 6). Die N-Wirkungen auf den Ertrag waren linear,

und die linearen Steigungen unterschieden sich nicht zwischen den Hybriden (Abbildung 6a), obwohl der Achsenabschnitt einen größeren Ertrag mit später reifenden Hybriden zeigt. Im Gegensatz dazu war die N-Wirkung in der Region Nord höher als in den Regionen Nordwest und Mitte und sowohl linearer als auch quadratischer Terme waren signifikant (Abbildung 6b).



**Abbildung 6. Quadratische Modelle für die Wechselwirkung Hybride x N-Düngung (a) und Region x N-Düngung (b).** Die dargestellten Punkte sind die beobachteten arithmetischen Mittelwerte. Das  $R^2_{adj}$  bezieht sich auf das angepasste Bestimmtheitsmaß der quadratischen Modelle. RSE = Residualstandardfehler. Gegeben sind Vergleiche der linearen Steigungen zwischen den Hybriden (a) und zwischen den Regionen (b). N = Nord, NW = Nordwest, M = Mitte.

## Diskussion

### Regionale Variation in N-Verdünnungskurven

Die Hypothese dieser Studie war, dass für eine Abschätzung der N-Ernährung von Silomais hybrid- oder regions-spezifische N-Verdünnungskurven erforderlich sind. Basierend auf unseren Ergebnissen kann diese Hypothese abgelehnt werden (Tabelle 4). Numerische Unterschiede in den Koeffizienten a und b zwischen den Regionen können durch Unterschiede in der Biomasseakkumulation erklärt werden, die durch die unterschiedlichen Wetterbedingungen und Wechselwirkungen, die durch Ko-Limitierung von Wasser und N verursacht werden (Kunrath et al. 2020; Pandey et al. 2000). Hier ist insbesondere auf die extreme Trockenheit während der Saison 2022 in der nordwestlichen und mittleren Region hinzuweisen. Gravimetrische Bodenfeuchtheitsmessungen zu mehreren Zeitpunkten während der Saison zeigten, dass die Regionen Nordwest und Mitte unter Wasserstress litten, mit jeweils 58% bzw. 42% weniger Bodenfeuchtigkeit im Jahr 2022 im Vergleich zu 2021 (Daten nicht gezeigt). Im Vergleich dazu war die Variation der Bodenfeuchtigkeit zwischen den Jahren in der Region Nord mit nur 14% weniger Feuchtigkeit im Jahr 2022 im Vergleich zu 2021 geringer (nicht gezeigt). Die Region Mitte hatte 2022 während des vegetativen Wachstums im Juni und nach der Blüte im August Trockenstress, während Trockenheit im Nordwesten eine größere Rolle nach der Blüte spielte. Eine geringere Wasserversorgung erhöhte den Koeffizienten a der N-Verdünnungskurve numerisch in einer Meta-Analyse von Ciampitti et al. (2021b). Allerdings gibt es gemäß der Analyse dieser letzten Studie keine Hinweise auf einen signifikanten Effekt der Wasserbegrenzung auf die N-Verdünnungskurve, da sie keinen erhöhten Anstieg von N-reichen Verbindungen in Pflanzenzellen bei geringerer Wasserversorgung und auch keine Änderungen in den Biomasseallokationsmustern fanden. Dies war mutmaßlich darauf zurückzuführen, dass der Trockenstress nicht stark genug war. Zusätzlich zum starken Trockenstress in den Regionen Nordwesten und Mitte im Jahr 2022 deutet unsere eigene Analyse auf einen Effekt der Trockenheit auf die Biomasseallokation hin. In den beiden trockengestressten Regionen Nordwest und Mitte fand eine leichte Verschiebung der Allokation zugunsten des Stängels auf Kosten der Kolben im Jahr 2022 im Vergleich zu 2021 statt (Tabelle S1). Ein Rückgang der Kolbenbiomasse wirkt sich wahrscheinlich auf die N-Verdünnung durch reduzierte Biomasseproduktion aus (Ciampitti und Vyn 2012), als Folge einer Sinkbeeinträchtigung nach der Blüte (Ning et al. 2018). Daher könnte der stärkere Effekt der Trockenheit in unserer Studie im Vergleich zu der Studie von Ciampitti et al. (2021b) und eine marginale Änderung in der Biomasseallokation eine größere Erhöhung der Ncrit-Koeffizienten in den von Dürre betroffenen Regionen verursacht haben.

Der Koeffizient a lag zwischen 3.82 in der Region Nord und 4.97 in der Region Nordwest (Tabelle 4), was auf eine höhere anfängliche N-Konzentration im Nordwesten aufgrund der geringeren Biomasseakkumulation hinweist. Die Biomasseerträge zu Beginn der Vegetationsperiode (bei ca. BBCH 16) zeigten die Rangfolge Nord > Mitte > Nordwesten (nicht gezeigt). Allerdings zeigen die Überlappungen der Konfidenzintervalle, dass die regionale Variation der Ncrit-Koeffizienten nicht statistisch signifikant war (Tabelle 4). Insgesamt war eine N-Düngung von 180 kg N ha<sup>-1</sup> ausreichend, um NNI-Werte nahe 1 im Norden zu erreichen. Aufgrund der Dürre lag der NNI in den Regionen Nordwesten und Mitte jedoch nie über 1, was auch von Kunrath et al. (2020) beobachtet wurde. Dies zeigt, dass Ncrit und NNI nicht zur Ableitung des absoluten N-Düngebedarfs zur Erreichung des erforderlichen Bereichs im Allgemeinen und besonders unter Trockenheit verwendet werden

können. An Wasserknappheit leidende Anbausysteme weisen im Allgemeinen einen niedrigeren NNI auf als bewässerte Kontrollen, und dieser Effekt ist stärker ausgeprägt, wenn die N-Versorgung hoch ist (Gonzalez-Dugo et al. 2010). Das Wurzel-zu-Spross-Verhältnis nimmt unter Trockenheit zu, da die oberirdische Biomasseakkumulation reduziert wird (Seidel et al. 2024). Wurzeln wachsen unter Trockenheit bis zu einem gewissen Grad weiter (Werner et al. 2022), jedoch haben Wurzeln im Allgemeinen eine geringere N-Konzentration als die oberirdische Biomasse (Watson 1996). Die Änderung der Biomasseallokation hin zu den Wurzeln unter Dürre reduziert daher den N-Bedarf von Mais und somit auch die N-Aufnahme.

#### *Sorten-spezifische Variation in N-Verdünnungskurven*

Obwohl frühere Studien Ncrit als Werkzeug zur Bewertung der N-Düngung im Maisanbau bei der Ernte vorgeschlagen haben (Herrmann und Taube 2005), überschreiten die N-Konzentrationen in Silageproben von Silomais in Deutschland immer noch den empfohlenen Wert (LUFÄ Nord 2023; Proteinmarkt 2022), was darauf hinweist, dass das Konzept des NNI in der Praxis nicht akzeptiert und angewendet wird. Der Grund für die Ablehnung des Konzepts in der Praxis könnte erstens darin liegen, dass Mais vor der Aussaat gedüngt wird, während N-Konzentrationsdaten nur nach der Ernte verfügbar sind. Zweitens gibt es in der Praxis die Annahme, dass Maishybriden unterschiedliche N-Konzentrationen bei maximalem Ertrag in Sortentests aufweisen (Eiler und Bauer 2014). Genetische Unterschiede in der N-Nutzungseffizienz bei Körnermais wurden sowohl bei niedrigen als auch hohen N-Düngeniveaus beobachtet (Gallais und Hirel 2004), wobei die Körnerzahl pro Kolben am stärksten durch N-Limitierung beeinflusst wird (Wu et al. 2011). Zhang et al. (2020) dokumentierten genotypische Unterschiede in der N-Aufnahme und N-Verlagerung nach der Blüte und unterstrichen damit die Annahmen einer genotypischen Variation. Dies könnte darauf zurückzuführen sein, dass es Wechselwirkungen zwischen Genotyp und Umwelt gibt, die die Quellen-Senke-Beziehungen beeinflussen (Ciampitti et al. 2021a), und dass Maishybride in ihrer N-Aufnahmerate variieren können (He et al. 2024). Die vorliegende Analyse stimmt jedoch nicht mit diesen Studien überein. Laut Ciampitti et al. (2021a) sind genotypische Unterschiede in den Koeffizienten der Verdünnungskurve auf Unterschiede in der Lichtabsorption zurückzuführen. Die in dieser Studie verwendeten Hybriden waren allesamt dreifach-Maishybriden, die sich nur in der Reifegruppe unterschieden, jedoch unter identischem Management angebaut wurden. Die gesammelten Biomasseallokationsdaten zeigen auch sehr ähnliche Organallokationsmuster zwischen den Hybriden (Tabelle S1). Dies deutet darauf hin, dass sortenspezifische Effekte auf N-Dilutionskurven unwahrscheinlich sind, wobei eine Einschränkung der vorliegenden Studie die begrenzte Variation zwischen den getesteten Reifegruppen sein könnte. Die Schlussfolgerung wird jedoch weiter durch eine starke Überlappung der Konfidenzintervalle der Koeffizienten a und b der Ncrit-Kurven zwischen den Hybriden unterstützt.

Frühere Studien wählten in der Regel entweder eine Hybride, die an mehreren Standorten angebaut wurde (Plénet und Lemaire 1999; Ziadi et al. 2008), oder mehrere Hybriden, die an einem Standort angebaut wurden (z. B. Ciampitti et al. (2013), Herrmann und Taube (2004)), während nur wenige Studien eine Reihe verschiedener Hybriden an mehreren Standorten verwendet haben (z. B. Chen et al. (2010); Herrmann und Taube (2005)). Soweit wir wissen, ist dies die erste Studie, die drei Hybriden mit unterschiedlicher Reifegruppe unter kontrastierenden Umweltbedingungen bewertet hat, weshalb der Ansatz dieser Studie gerechtfertigt erscheint, um unsere Frage zu beantworten. Insgesamt kann diese Studie als Fallbeispiel dienen, dass frühe bis mittelfrühe Maishybriden unter den aktuellen klimatischen Bedingungen und auch unter den laufenden klimatischen Veränderungen mit zunehmenden Dürreereignissen in Zukunft die gleichen Ncrit-Funktionen aufweisen werden.

#### *Bewertung der Verdünnungskoeffizienten*

Trotz des gewählten Ansatzes stimmten unsere Koeffizienten a und b mit denen überein, die ursprünglich von Plénet und Lemaire (2000) unter Verwendung mehrerer Maishybriden bis zur Blüte + 25 Tage berichtet wurden (Abbildung 1). Sie liegen auch nahe bei denen, die in anderen und neueren Studien für Mais berichtet wurden (Ciampitti et al. 2021a; Herrmann und Taube 2004; Sieling und Kage 2021). Die abgeleiteten mittleren Ncrit-Funktionskoeffizienten (Abbildung 4) lagen unter der maximalen Funktionskurve für Mais ( $a=6.3$ ,  $b=0.42$ ) (Plénet und Cruz 1997), was die Fähigkeit von Mais anzeigt, überschüssiges N zu akkumulieren. Außerdem zeigt die Überlappung der Konfidenzintervalle mit den Koeffizienten von Plénet und Lemaire (1999) (Tabelle 3), dass die bereits etablierten Ncrit-Kurven und abgeleiteten NNI-Werte unabhängig vom Zuchtfortschritt, laufenden Umweltveränderungen oder Änderungen der Maisanbaupraktiken mit später reifenden Hybriden auch in nördlichen Regionen verwendet werden können. Wenn der Rückgang der N-Konzentration in Pflanzen als Funktion der Erntebiomasse über Regionen und Hybriden bis zum Teigstadium auf einer Log/Log-Skala berechnet wird, ergibt sich eine Steigung von 0.37, was genau der von Plénet und Cruz (1997) für Mais berichteten Steigung entspricht – was weiter unterstreicht, dass es keine Notwendigkeit für alternative Ncrit-Funktionen für spezifische Hybriden oder Wachstumsbedingungen gibt. Laut Vos et al. (2005) wird die maximale Photosynthese in Mais bei N-Konzentrationen von 3.5 % erreicht, was nahe dem Koeffizienten a unserer eigenen Berechnung liegt (Abbildung 4, Tabelle 4). Andererseits wird erwartet, dass unsere Koeffizienten der Ncrit-Kurve von der Studie von Plénet und Lemaire (1999) abweichen, da wir die N-Verdünnung bis zum Teigstadium im Einklang mit Herrmann und Taube (2005, 2004) quantifiziert haben. Wenn die N-Verdünnung mit unseren Daten bis zur Blüte berechnet wird, betragen die Koeffizienten a und b 4.38 bzw. 0.45, was noch näher bei den von Plénet und Lemaire (1999) berichteten Werten liegt. Herrmann

und Taube (2005) fanden für den maximalen Ertrag zum Zeitpunkt der Silomaisreife einen Ncrit-Wert von 10.5 g N kg<sup>-1</sup> TM. Wenn der gleiche Ansatz wie in der letzten genannten Studie verwendet wird, um den Ncrit für den maximalen Biomasseertrag in unserer Studie zu bewerten, ergibt sich mit unseren Daten ein Ncrit-Wert von 9.1 g N kg<sup>-1</sup> TM, was darauf hinweist, dass neuere Hybriden N effizienter nutzen als Hybriden vor zwei Jahrzehnten, im Einklang mit Ciampitti und Vyn (2012), die einen höheren Mais Kornenertrag bei ähnlicher N-Aufnahme feststellten.

## Schlussfolgerungen

Die beobachteten Ncrit-Kurven zeigten keine signifikante Variation zwischen den Hybriden oder Regionen. Numerische regionale Variation kann durch die extreme Dürre mit früheren Ernten in zwei der drei Regionen während eines Jahres erklärt werden. Diese Studie kann als Fallbeispiel herangezogen werden, um zu zeigen, wie moderne Hybriden in Zukunft bei fortschreitenden klimatischen Veränderungen performen werden, wenn sich die Maisanbaupraktiken durch die Ausbreitung später reifender Hybriden in nördliche Breiten verändern.

## Anhang

**Table S 1. Geschätzte Mittelwerte ± Standardfehler der Blätter-, Stängel- und Kolbenfraktionen sowie des TS-Gehaltes (TS, %) zur Teigreife. Kleinbuchstaben zeigen signifikant unterschiedliche Mittelwerte zwischen den Hybriden je Region und Jahr (P<0,05). NR = Nord, NWR = Nordwest, MR = Mitte Region. F = Fraktion. Angezeigt sind Mittelwerte über zwei N-Düngungsniveaus (0 und 180 kg N ha<sup>-1</sup>).**

Jahr	Region	Hybrid	F_Blatt	F_Stengel	F_Kolben	TS (%)
<b>J x R x H-Interaktion</b>			<b>P&lt;0.001</b>	<b>P&lt;0.001</b>	<b>P&lt;0.001</b>	<b>P=0.07</b>
<b>2021</b>	<b>NR</b>	<b>S210</b>	0.13 ± 0.02 a	0.33 ± 0.02 a	0.45 ± 0.03 a	31.5 ± 1.5
		<b>S250</b>	0.12 ± 0.02 a	0.30 ± 0.02 a	0.49 ± 0.03 a	35.9 ± 1.7
		<b>S260</b>	0.13 ± 0.02 a	0.33 ± 0.02 a	0.45 ± 0.03 a	28.8 ± 1.5
	<b>NWR</b>	<b>S210</b>	0.23 ± 0.03 b	0.44 ± 0.02 b	0.29 ± 0.02 a	31.3 ± 1.6
		<b>S250</b>	0.11 ± 0.01 a	0.16 ± 0.01 a	0.64 ± 0.02 b	34.5 ± 1.7
		<b>S260</b>	0.11 ± 0.01 a	0.15 ± 0.01 a	0.64 ± 0.02 b	35.4 ± 1.7
	<b>MR</b>	<b>S210</b>	0.14 ± 0.02 a	0.23 ± 0.01 a	0.58 ± 0.03 a	30.1 ± 1.6
		<b>S250</b>	0.15 ± 0.02 a	0.24 ± 0.02 a	0.56 ± 0.03 a	36.5 ± 1.7
		<b>S260</b>	0.17 ± 0.02 a	0.23 ± 0.02 a	0.54 ± 0.03 a	35.9 ± 1.7
<b>2022</b>	<b>N</b>	<b>S210</b>	0.06 ± 0.01 a	0.26 ± 0.02 a	0.57 ± 0.03 b	35.3 ± 1.7
		<b>S250</b>	0.09 ± 0.01 ab	0.33 ± 0.02 b	0.49 ± 0.03 ab	29.9 ± 1.6
		<b>S260</b>	0.1 ± 0.01 b	0.33 ± 0.02 b	0.45 ± 0.03 a	27.9 ± 1.5
	<b>NW</b>	<b>S210</b>	0.11 ± 0.01 ab	0.26 ± 0.02 a	0.51 ± 0.03 b	33.0 ± 1.7
		<b>S250</b>	0.16 ± 0.02 b	0.30 ± 0.02 a	0.42 ± 0.02 a	40.4 ± 1.8
		<b>S260</b>	0.10 ± 0.01 a	0.28 ± 0.02 a	0.43 ± 0.03 ab	38.3 ± 1.8
	<b>M</b>	<b>S210</b>	0.17 ± 0.02 a	0.26 ± 0.02 a	0.50 ± 0.03 a	30.3 ± 1.6
		<b>S250</b>	0.07 ± 0.01 b	0.24 ± 0.02 a	0.61 ± 0.02 b	34.0 ± 1.7
		<b>S260</b>	0.05 ± 0.01 a	0.24 ± 0.02 a	0.64 ± 0.03 b	35.1 ± 1.7

## Datenanalyse, Teil 2: Verbesserung der Stickstoffnutzungseffizienz von Silomais (*Zea mays* L.) durch die Wahl von Reifegruppe und Stickstoffinput unter kontrastierenden Umweltbedingungen

### Kurzfassung

Die Reifegruppen von Silomais (*Zea mays* L.) Hybriden unterscheiden sich in der Dauer des vegetativen Wachstums und der Abreife, was sich auf die finale Biomasse- und Stickstoffakkumulation auswirkt. Frühe Hybriden werden für kühlere Regionen im Norden empfohlen, da sie geringere Biomasseerträge produzieren, während spätere Hybriden in wärmeren Regionen angebaut werden, um höhere Erträge zu ermöglichen. Da die effizientere Nutzung von Stickstoff (N) die politische Agenda in Europa dominiert, war die Frage dieser Studie, ob Hybriden, die sich in ihrer Reifegruppe unterscheiden, unterschiedliche N-Düngungshöhen für maximales Wachstum benötigen und ob dies unter kontrastierenden Umweltbedingungen variiert. In dieser Studie wurde daher die Beziehung zwischen der Reifegruppe (früh, mittel-früh und mittel-spät, d. h. S210, S250 und S260) und dem mineralischen N-Input (0, 60, 120, 180, 240, 300 kg N ha<sup>-1</sup>) hinsichtlich

Biomasseproduktion, N-Aufnahme ( $N_{up}$ ), N-Nutzungseffizienz (NUE,  $\text{kg TM kg}^{-1} \text{ N verfügbar}$ ) und physiologischer Effizienz (PE,  $\text{kg TM kg}^{-1} \text{ Nup}$ ) in drei Regionen Deutschlands (Nord, Nordwest, Mitte) während eines feuchten und eines trockenen Jahres untersucht. Wir erwarteten signifikante Interaktionseffekte von Hybrid x Region x N-Input auf die Zielvariablen, die jedoch nur für  $N_{up}$  festgestellt wurde. Dies war auf eine geringere  $N_{up}$  von S250 im Vergleich zu den beiden anderen Hybriden in der Nordregion zurückzuführen. Über alle N-Input-Raten, Regionen und Jahre hinweg waren genotypische Effekte auf keine der getesteten Parameter vorhanden. Ein auffälliges Ergebnis war das Fehlen einer N-Reaktion in den Regionen Nordwest und Mitte. In der Region Mitte verhinderte die späte Aussaat im Jahr 2021 eine vollständige Ausnutzung des Ertragspotenzials, während 2022 Trockenheit die Biomasseproduktion begrenzte. In Nordwesten führte ebenfalls Trockenheit und zusätzlich das hohe N-Mineralisierungspotenzial im Boden zu einem Ausbleiben der N-Reaktion. Insgesamt scheint es in Anbetracht der vorliegenden Daten keine Notwendigkeit für ein angepasstes N-Düngungsmanagement zu geben, wenn Hybriden unterschiedlicher Reifegruppen in unterschiedlichen Regionen oder unterschiedlichen Klimabedingungen angebaut werden. Allerdings ist davon auszugehen, dass die Klimabedingungen Sorteneffekte unter Umständen überlagern.

## Zielstellung

Das Ziel dieser Studie war es, die Variabilität der N-Nutzungseffizienz von drei Maissorten unterschiedlicher Abreife unter kontrastierenden Umweltbedingungen zu prüfen. Wir stellten die Hypothese auf, dass Maissorten aufgrund ihrer Abreifegeschwindigkeit und aufgrund eines höheren Ertragspotentials später abreifender Sorten unterschiedliche optimale N-Düngemengen benötigen und dass diese von den Umweltbedingungen abhängt.

## Ergebnisse

Der Ertrag wurde signifikant durch die Wechselwirkungen von Region x N-Düngung ( $F(10.338)=5$ ,  $p<0.0001$ ) und von Hybride x Region x Jahr ( $F(4.338)=4$ ,  $p<0.01$ ) beeinflusst (Tabelle 5). Die N-Aufnahme ( $N_{up}$ ) wurde signifikant durch die Wechselwirkungen von Hybride x Jahr ( $F(2.337)=13$ ,  $p<0.0001$ ), von Region x Jahr ( $F(2.337)=86$ ,  $p<0.0001$ ) und von Hybride x Region x N-Düngung ( $F(20.337)=2$ ,  $p<0.05$ ) beeinflusst (Tabelle 5).

**Tabelle 5. Die p-Werte der linearen gemischten Effektmodelle für den Pflanzenbiomasse-Ertrag ( $\text{t TM ha}^{-1}$ ), die N-Aufnahme ( $N_{up}$ ,  $\text{kg N ha}^{-1}$ ), die Stickstoffnutzungseffizienz ( $NUE_{DM}$ ,  $\text{kg TM kg}^{-1} \text{ Nav}$ ) und die physiologische Effizienz (PE,  $\text{kg TM kg}^{-1} \text{ Nup}$ ) zum Zeitpunkt der Maisernte. RMSE = Wurzel des mittleren quadratischen Fehlers, MAE = mittlerer absoluter Fehler. p-Werte für signifikante Wechselwirkungen, die in weiteren gruppenweisen Vergleichen berücksichtigt wurden, sind fett hervorgehoben.**

Effects	Biomasse	N-Aufnahme	$NUE_{DM}$	PE
Hybrid (H)	$p=0.0001$	$p=0.053$	$p=0.011$	$p=0.463$
Region (R)	$p<0.0001$	$p<0.0001$	$p<0.0001$	$p=0.135$
Jahr (Y)	$p<0.0001$	$p<0.0001$	$p<0.0001$	$p=0.187$
N input (N)	$p<0.0001$	$p<0.0001$	$p<0.0001$	$p<0.0001$
H x R	$p=0.4287$	$p=0.229$	$p=0.291$	$p=0.577$
H x Y	$p=0.0009$	<b><math>p&lt;0.0001</math></b>	$p=0.603$	$p=0.248$
H x N	$p=0.2110$	$p=0.345$	$p=0.121$	$p=0.512$
R x Y	$p<0.0001$	<b><math>p&lt;0.0001</math></b>	$p<0.0001$	$p=0.483$
R x N	<b><math>p&lt;0.0001</math></b>	$p<0.0001$	$p=0.053$	<b><math>p=0.017</math></b>
Y x N	$p=0.0816$	$p=0.253$	$p<0.0001$	$p=0.105$
H x R x Y	<b><math>p=0.0021</math></b>	$p=0.070$	<b><math>p&lt;0.0001</math></b>	$p=0.212$
H x R x N	$p=0.5010$	<b><math>p=0.049</math></b>	$p=0.904$	$p=0.741$
H x Y x N	$p=0.9133$	$p=0.954$	$p=0.474$	$p=0.915$
R x Y x N	$p=0.2792$	$p=0.159$	<b><math>p&lt;0.0001</math></b>	$p=0.379$
$R^2$	0.82	0.82	0.89	0.61
RMSE	2.6	31	14	10.5
MAE	2.1	23	11	7.8

Die Ertragsreaktion auf mineralischen N-Dünger war in NR signifikant höher als in den anderen beiden Regionen (Abbildung 7). Der Anstieg der N-Aufnahme ( $N_{up}$ ) von S250 in NR war signifikant geringer als bei den anderen Hybriden, während in allen anderen Fällen keine Unterschiede zwischen den Hybriden festgestellt wurden (Abbildung 8). Unterschiede in den Steigungen der  $N_{up}$  zwischen den Regionen waren meistens zwischen NR und NWR oder MR signifikant. Die Steigungen zwischen NWR und MR waren nicht signifikant verschieden (Abbildung 8). Optimale N-Düngungshöhen konnten aufgrund der stark divergierenden Witterungsbedingungen zwischen den Jahren für die einzelnen Standorte nicht zuverlässig ermittelt werden. Geprüft wurden quadratische Regressionen und Linear-Plateau-Ansätze.

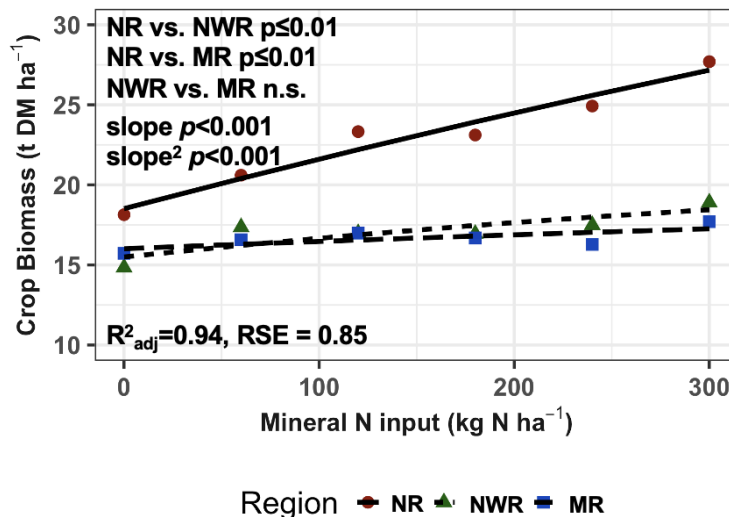


Abbildung 7. Quadratische Modelle für die Wechselwirkung zwischen Region und N-Düngung für den Ertrag an Pflanzenbiomasse. Die dargestellten Punkte repräsentieren die beobachteten arithmetischen Mittelwerte über die Jahre hinweg. Das  $R^2_{adj}$  bezieht sich auf das angepasste Bestimmtheitsmaß des quadratischen Modells. RSE = Residual Standard Error. Es werden Vergleiche der linearen Steigungen zwischen den Regionen angegeben. NR = Nord, NWR = Nordwest, MR = Mitte.

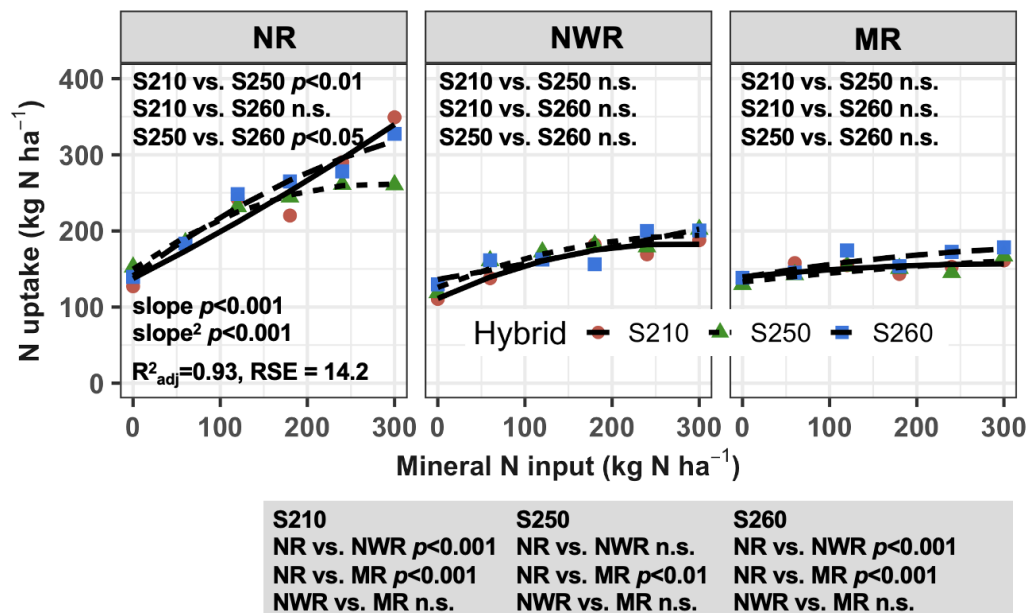


Abbildung 8. Quadratische Modelle für die Interaktion von Hybrid x Region x N-Düngung für die N-Aufnahme. Die geplotteten Punkte stellen die beobachteten arithmetischen Mittel über die Jahre dar. Das  $R^2_{adj}$  bezieht sich auf die angepassten quadratischen Modelle. RSE = Residualstandardfehler. Es werden Vergleiche der linearen Steigungen zwischen den Hybriden innerhalb der Region und zwischen den Regionen innerhalb des Hybriden gegeben (unteres graues Feld). NR = Nord, NWR = Nordwesten, MR = Mittelregionen.

Vergleiche der Mittelwerte zeigten, dass die Erträge und die N-Aufnahme (Nup) im Jahr 2021 im Vergleich zu 2022 größer waren (Tabellen 6 und 7). Die Erträge von S260 waren in NWR im Jahr 2021 und in NR und MR im Jahr 2022 signifikant höher als die der beiden anderen Hybriden (Tabelle 6). Die Unterschiede im Ertrag zwischen den Regionen änderten sich im Laufe der Jahre. Im Jahr 2021 folgten die Reihenfolge des Ertrages und der N-Aufnahme der Rangordnung  $NR > MR > NWR$ . Diese Rangordnung änderte sich im Jahr 2022 auf  $NR > NWR > MR$  (Tabellen 6 und 7B). Der Hybride S260 erzielte im Jahr 2022 eine signifikant größere N-Aufnahme als die anderen Hybriden (Tabelle 7A).

Tabelle 6. Geschätzte Mittelwerte  $\pm$  SE des Ertrages ( $t \text{ TM ha}^{-1}$ ) als Einfluss der Interaktion von Jahr x Hybrid x Region. Kleinbuchstaben weisen auf signifikant unterschiedliche Mittelwerte zwischen den Hybriden pro Jahr und Region hin. Großbuchstaben zeigen signifikante Unterschiede zwischen den

Regionen pro Hybrid und Jahr. Symbole #\\$ zeigen signifikante Unterschiede zwischen den Jahren innerhalb des Hybriden und der Region ( $p < 0.05$ ). NR = Nord, NWR = Nordwesten, MR = Mittelregionen.

Jahr	Region Hybrid	NR		NWR		MR				
		Mittel	SE	Mittel	SE	Mittel	SE			
2021	S210	27.2	0.85	aC#	19.0	0.67	aA#	21.8	0.66	aB#
	S250	26.6	0.85	aC#	20.1	0.67	abA#	22.7	0.67	aB#
	S260	24.9	0.85	aB#	21.4	0.66	bA#	22.8	0.66	aAB#
2022	S210	18.6	0.85	aC\$	13.1	0.66	aB\$	9.9	0.66	aA\$
	S250	18.3	0.85	aC\$	14.2	0.66	aB\$	10.5	0.66	aA\$
	S260	22.2	0.85	bC\$	14.8	0.66	aB\$	12.6	0.66	bA\$

Tabelle 7. Geschätzte Mittelwerte  $\pm$  SE der N-Aufnahme ( $\text{kg N ha}^{-1}$ ) für die Interaktion von Jahr x Hybrid A) und Jahr x Region B). Kleinbuchstaben weisen auf signifikant unterschiedliche Mittelwerte zwischen den Hybriden (A) oder zwischen den Regionen (B) pro Jahr hin. Symbole #\\$ zeigen signifikante Unterschiede zwischen den Jahren innerhalb des Hybriden (A) oder der Region (B) ( $p < 0.05$ ). NR = Nord, NWR = Nordwesten, MR = Mittelregionen.

	Jahr	Hybrid	Mittel	SE	
A)	2021	S210	225	6.4	a#
		S250	217	6.4	a#
		S260	213	6.4	a#
	2022	S210	138	6.4	a\$
		S250	145	6.4	a\$
		S260	166	6.4	b\$
B)	2021	NR	263	7.4	c#
		NWR	183	5.8	a#
		MR	210	5.8	b#
	2022	NR	203	7.4	c\$
		NWR	148	5.8	b\$
		MR	98	5.8	a\$

Die Interaktion von Jahr x Region x N-Düngung war für die Stickstoffnutzungseffizienz ( $\text{NUE}_{\text{DM}}$ ) signifikant ( $F(10.338) = 13$ ,  $p < 0.0001$ ) (Tabelle 5). Signifikante Unterschiede zwischen den regionalen linearen Steigungen wurden nur im Jahr 2022 gefunden, mit steileren Steigungen in NWR und MR im Vergleich zu NR (Abbildung 9). Der Vergleich der Steigungen zwischen den Jahren innerhalb jeder Region ergab signifikant größere Steigungen im Jahr 2022 im Vergleich zu 2021 ( $p < 0.001$ ) sowohl in den Regionen NWR als auch MR.

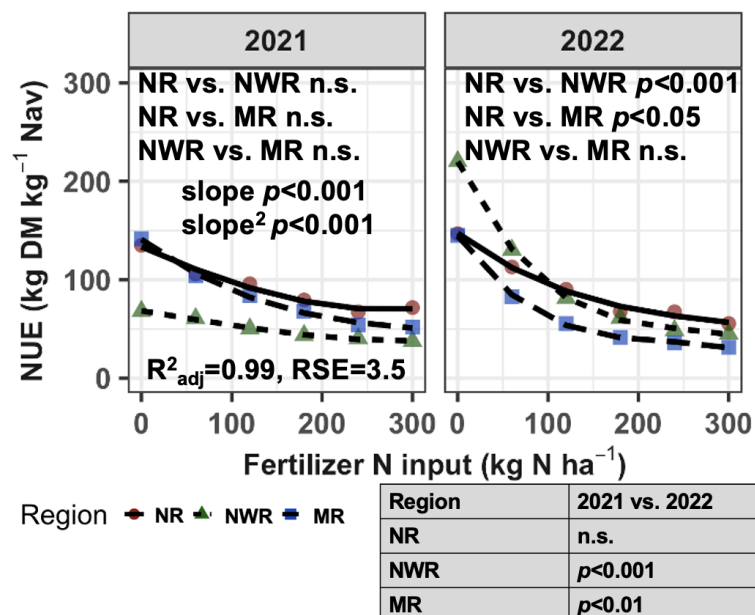


Abbildung 9. Quadratische Modelle für die Interaktion von Jahr x Region x N-Düngung auf die Stickstoffnutzungseffizienz ( $\text{NUE}_{\text{DM}}$ ,  $\text{kg TM kg}^{-1}$  Nav). Die dargestellten Punkte sind die beobachteten

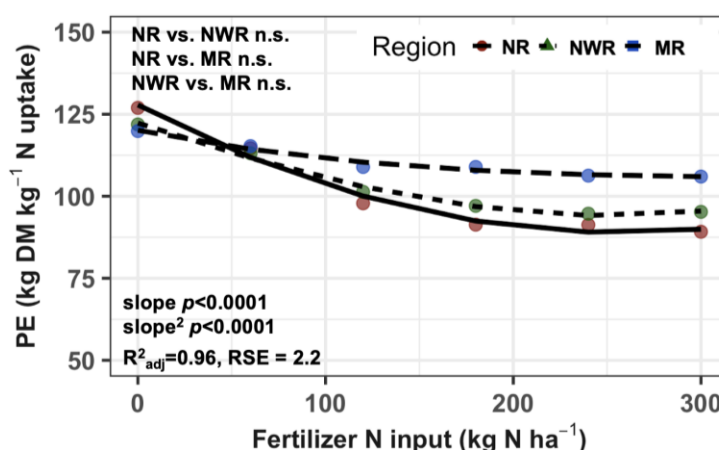
arithmetischen Mittel über alle Hybriden hinweg. Das  $R^2_{adj}$  bezieht sich auf das angepasste Bestimmtheitsmaß des quadratischen Modells. RSE = Residualstandardfehler. Gegeben sind die Vergleiche der linearen Steigungen zwischen den Regionen pro Jahr. Die Tabelle im unteren Teil zeigt die Vergleiche der linearen Steigungen zwischen den Jahren pro Region. NR = Nord, NWR = Nordwesten, MR = Mittelregionen.

Es wurden keine genotypischen Effekte in Wechselwirkung mit der N-Düngung auf die  $NUE_{DM}$  festgestellt. Allerdings war die Wechselwirkung von Hybrid x Region x Jahr signifikant für die  $NUE_{DM}$  ( $F(4.338) = 8$ ,  $p < 0.0001$ ) (Tabelle 5). Die Variation zwischen den Regionen zeigte die Reihenfolge  $NR \geq MR > NWR$  im Jahr 2021 und  $NWR \geq NR > MR$  im Jahr 2022 (Tabelle 8). Der Jahreseffekt unterschied sich je nach Region. Während in der Region NWR die  $NUE_{DM}$  2022 höher war als 2021, war das Gegenteil in der Region MR der Fall (Tabelle 8). Im Gegensatz dazu wurde in NR kein Unterschied zwischen den Jahren bei der  $NUE_{DM}$  festgestellt. S210 erzielte in 2021 in NR signifikant höhere  $NUE_{DM}$ -Werte im Vergleich zu allen anderen Hybriden. In 2022 war der Unterschied nur für S250 signifikant. Andererseits erzielte S260 in 2022 in NR eine höhere  $NUE_{DM}$  als alle anderen Hybriden (Tabelle 8).

**Tabelle 8. Geschätzte Mittelwerte  $\pm$  SE der Stickstoffnutzungseffizienz ( $NUE_{DM}$ , kg TM  $kg^{-1}$  Nav) wurden in Abhängigkeit von der Wechselwirkung zwischen Jahr x Hybrid x Region analysiert. Kleinbuchstaben zeigen signifikant unterschiedliche Mittelwerte zwischen den Hybriden innerhalb jedes Jahres und jeder Region. Großbuchstaben zeigen signifikante Unterschiede zwischen den Regionen innerhalb jeder Hybride und Jahres. Symbole # und \$ weisen auf signifikante Unterschiede zwischen den Jahren für jede Hybride und jede Region hin ( $p < 0.05$ ). Nav steht für Stickstoffverfügbarkeit. Die Regionen sind wie folgt angegeben: NR = Norden, NWR = Nordwesten MR = Mitte**

	Region		NR			NWR			MR		
	Jahr	Hybrid	Mittel	SE		Mittel	SE		Mittel	SE	
$NUE_{DM}$	2021	S210	101	3.8	bC\$	47	3.9	aA\$	85	3.8	aB\$
		S250	90	3.8	aB\$	51	3.9	aA\$	79	3.9	aB\$
		S260	88	3.9	aB\$	51	3.9	aA\$	86	3.9	aB\$
	2022	S210	89	3.8	aB\$	103	3.8	aC#	71	3.8	bA#
		S250	83	3.8	aB\$	97	3.8	aC#	60	3.8	aA#
		S260	99	3.9	bB\$	94	3.9	aB#	65	3.9	abA#

Die physiologische Effizienz (PE) wurde signifikant durch die Interaktion von Region x N-Düngung beeinflusst ( $F(10.326) = 1.8$ ,  $p < 0.0001$ ) (Tabelle 5). Obwohl die Steigungen der Reaktionen der PE auf die N-Düngung zwischen den Regionen nicht unterschiedlich waren (Abbildung 10), lag MR konstant auf einem höheren Niveau als NR und NWR. Über alle N-Düngungsstufen hinweg hatte die Region MR eine PE von 111  $kg TM kg^{-1} N_{up}$ , während die Regionen NWR und NR, Werte von 104 bzw. 102  $kg TM kg^{-1} N_{up}$  aufwiesen. Die PE und  $NUE_{DM}$  korrelierten negativ miteinander ( $\rho = 0.02$ ,  $R = -0.28$ ).



**Abbildung 10. Das quadratische Modell für die Interaktion von Region und N-Düngung auf die Stickstoffnutzungseffizienz (PE,  $kg TM kg^{-1} N_{up}$ ) ist unten dargestellt. Die geplotteten Punkte repräsentieren die beobachteten arithmetischen Mittelwerte über Hybriden und Jahre hinweg. Der  $R^2_{adj}$  bezieht sich auf das angepasste Bestimmtheitsmaß der angepassten quadratischen Modelle, während RSE den residualen Standardfehler darstellt. Vergleiche der linearen Steigungen zwischen den Regionen werden bereitgestellt, wobei NR = Norden, NWR = Nordwesten und MR = Mittelregionen sind.**

## Diskussion

Die Biomasseerträge dieser Studie stimmen weitgehend mit früheren Studien zu Silomais in Norddeutschland überein (Kayser et al. 2011; Herrmann und Rath 2012; Struck et al. 2019). Die maximalen Erträge in NR lagen

sehr nahe an den von Brauer-Siebrecht et al. (2016) aus Süddeutschland berichteten Werten. Dies wurde wahrscheinlich durch vergleichsweise wärmeres Wetter im Vergleich zu den langjährigen Temperaturen und eine günstige Verteilung ausreichender Niederschläge während der Wachstumsperiode 2021 verursacht. Ein auffälliges Ergebnis war das Fehlen einer N-Düngewirkung in MR und NWR. In MR verhinderte die späte Aussaat 2021 eine vollständige Ausnutzung des Ertragspotenzials (Schmidt et al. 2023), während im Jahr 2022 Trockenheit die Biomasseproduktion begrenzte (Kunrath et al. 2020; Wang et al. 2020). Teixeira et al. (2014) testeten den Effekt einer erhöhten N-Düngung unter unbegrenzten und wasserbeschränkten Bedingungen und fanden ebenfalls eine Reduktion der N-Aufnahme um 65% und keine N-Düngungswirkung, wenn Wasser begrenzt war. In NWR führte ebenfalls die Trockenheit und zusätzlich das hohe Mineralisierungspotenzial des Bodens zu einem Fehlen der N-Düngewirkung, wie es in einer früheren Studie in derselben Region (Kayser et al. 2011) festgestellt wurde. Dies wird durch einen hohen Nav und somit niedrige NUE in der Region NWR im Jahr 2021 veranschaulicht (Abbildungen 7 & 8). Die Ergebnisse untermauern frühere Befunde, die auf eine negative Beziehung zwischen N-Nutzungseffizienz und N-Düngung hinweisen (Ciampitti und Vyn 2012; Sieling et al. 2013; Sandaña et al. 2025). Lemaire und Ciampitti (2020) zeigten, dass die NUE von der potenziellen Wachstumsrate der Kulturpflanze und dem N-Status abhängt, der durch das NNI der Pflanze definiert ist. Die Variation in der potenziellen Pflanzenwachstumsfähigkeit in Bezug auf Umweltbedingungen beeinflusst den N-Bedarf für eine gegebene Bodennährstoffversorgung. Folglich verhält sich die NUE negativ zur N-Düngungsrate.

Das Potenzial zur Optimierung der N-Nutzungseffizienz durch Berücksichtigung von Umweltbedingungen war größer als das durch die Wahl früher oder später reifender Hybriden, da die Wechselwirkungen der Hybriden mit der N-Düngung von geringerer Bedeutung waren und nur für die N-Aufnahme in NR festgestellt wurden. Hier hatte S250 eine geringere N-Aufnahme mit steigender Düngung als die beiden anderen Hybriden (Abbildung 8). Die in dieser Studie verwendeten Genotypen waren alles Drei-Wege-Mais-Hybriden, die sich in ihrer Reifegruppe unterschieden. Zudem unterschieden sich die Maishybride in der Endospermform im Korn. Während die Hybriden S210 und S260 Intermediärtypen zwischen Flint und Dent sind, ist S250 eine Flint-Mais-Hybride, die für ein geringeres Ertragspotenzial bekannt sind (Unterseer et al. 2016). Dieses geringere Ertragspotenzial des Flint-Mais könnte sich in der sehr produktiven Umgebung der NR in der aktuellen Studie niedergeschlagen haben. Über alle N-Düngungsmengen hinweg waren genotypische Effekte für Ertrag,  $N_{up}$  oder NUE je nach Region oder Jahr größtenteils nicht vorhanden. Wenn Unterschiede festgestellt wurden, wies S260 eine bessere Leistung auf. Im Allgemeinen wurden daher Vorteile bei der Verwendung von mittelspäten Hybriden im Vergleich zu früheren Hybriden festgestellt. Dies stimmt gut mit einer Modellvorhersage für Niedersachsen überein, die den stärksten Ertragszuwachs für das 21. Jahrhundert im Zuge des Klimawandels zeigt, wenn spätere Hybriden angebaut werden (Degener und Kappas 2015). Das Ertragspotenzial späterer Hybriden wurde in der norddeutschen Praxis noch nicht vollständig erkannt, da mittelspäte Hybriden in Norddeutschland offiziell nicht empfohlen werden (Agricultural Chamber Lower Saxony 2024). Es ist allerdings davon auszugehen, dass spätreife Sorten mit einer größeren Unsicherheit zum Erreichen der Ziel-TS-Gehalte verbunden sind. Der Klimawandel wird die zukünftigen Wachstumsperioden durch höhere Durchschnittstemperaturen verlängern (Umweltbundesamt (UBA) 2023), was Anpassungen bei der Wahl von Hybriden ermöglicht. Alle Hybriden erreichten zumeist einen TM-Gehalt von 30-35% und überschritten diesen Bereich sogar in NWR im Jahr 2022 aufgrund einer beschleunigten Seneszenz, die durch die Trockenheit und die Hitzewelle verursacht wurde.

#### *Klimatische Effekte auf die N-Nutzungseffizienz*

Die festgestellten regionalen Unterschiede in der N-Düngewirkung und NUE, mit einer signifikanten Wirkung nur in NR, wurden größtenteils durch klimatische Bedingungen beeinflusst. Das Jahr 2022 war eines der trockensten und heißesten Jahre mit der höchsten Sonneneinstrahlung, die je in Deutschland gemessen wurde (Imbery et al. 2023). Der Mangel an Niederschlag verursachte ab Juni eine Trockenheit in MR und im August 2022 in NWR (Tabelle 2). Infolgedessen unterschied sich der Niederschlag in der Wachstumsperiode zwischen den Jahren 2021 und 2022 um 24%, 43% und 29% in NR, NWR und MR (Tabelle 2). Wenn die Wasserversorgung reichlich war (wie im Norden oder im Jahr 2021), stieg der Biomasseertrag mit N-Düngung, während in den von Trockenheit betroffenen Regionen keine Ertragssteigerung durch N-Düngung festgestellt werden konnte (Abbildung 7, Tabelle 6). Hugh und Richard (2003) fanden heraus, dass Trockenstress den Maisertrag verringerte, indem er die Aufnahme von photosynthetisch aktiver Strahlung durch die Seneszenz der unteren Blattschichten verringerte und damit die Strahlungsnutzungseffizienz senkte. Höhere Bodenfeuchtigkeit unterstützt den Nährstofffluss zu den Maiswurzeln, was die höhere N-Aufnahme 2021 im Vergleich zu 2022 und in NR im Vergleich zu den anderen Regionen erklärt (Abbildung 5, Tabelle 7). In einer Studie von Link et al. (2013), die in Süddeutschland über drei Jahre durchgeführt wurde, war die NUE im trockeneren Jahr leicht niedriger als in den feuchteren Jahren. Daraus geht hervor, dass der angewandte N-Dünger unter Trockenheit viel weniger effizient in Ertrag umgesetzt wird als unter höherer Wasserversorgung (Ehlers und Goss 2016). Dies stimmt mit einer zweijährigen Studie von Wang et al. (2020) in China überein, die eine niedrigere NUE von zwei Mais-Hybriden in einem trockenen Jahr im Vergleich zu einem feuchten Jahr mit einem Unterschied von 60% im Niederschlag zwischen den Jahren fanden.

Die  $NUE_{DM}$  und PE in der vorliegenden Studie unterschieden sich ebenfalls zwischen den Jahren, jedoch nicht in der gleichen Richtung wie in den früheren Studien zu NUE in feuchten und trockenen Jahren (Wang et al.

2020; Teixeira et al. 2014; Link et al. 2013). Die Biomasseerträge waren in den Regionen NR, NWR und MR im Jahr 2022 25%, 30% bzw. 51% niedriger als im Jahr 2021 (Tabelle 6). Die  $NUE_{DM}$  war in NWR in 2022 höher als in 2021, während sie in MR im Jahr 2021 im Vergleich zu 2022 niedriger war. Trockenheit kann die mikrobielle Biomasse im Boden verringern (Homyak et al. 2017), die mikrobielle Aktivität im Boden verlangsamen und zu einer reduzierten N-Mineralisierungsrate führen (Borken und Matzner 2009). Dies geht einher mit einem geringeren Massentransport von Nitrat in der Bodenlösung zu den Wurzeln (Buljovic und Engels 2001) und einer geringeren Nitrataufnahme (Gloser et al. 2020). Die höhere Wahrscheinlichkeit für eine geringere N-Mineralisierung im Jahr 2022 ging mit einer reduzierten N-Aufnahme einher. Ge et al. (2012) berichten von einem durchschnittlichen Rückgang der Spross-Biomasse um 31% durch Trockenstress vom Dreiblattstadium bis zur Reife des Mais, was den N-Bedarf verringert und eine erhöhte Allokation der Biomasse zu den Wurzeln induziert (Poorter et al. 2012). In einem Mesokosmos-Experiment von Buljovic und Engels (2001) nahm die Maiswurzelbiomasse unter sehr trockenen Bodenbedingungen ab, und sie fanden auch eine 80%ige Reduktion der Wurzelnitrataufnahme, als die Wasserversorgung um 78% im Vergleich zur ungestressten Kontrolle sank. Das bedeutet, dass die beobachteten signifikanten Unterschiede in der  $NUE_{DM}$  zwischen den Jahren in den Regionen NWR und MR durch zwei verschiedene Mechanismen verursacht wurden: (i) die Reduzierung des N-Bedarfs der Kultur aufgrund der Reduzierung der Pflanzenmasse aufgrund von Wasserstress und (ii) die Verringerung der Boden-N-Verfügbarkeit in Verbindung mit einer Bodenwasserbeschränkung (Lemaire und Ciampitti 2020), die die  $NUE$  des Mais beeinflusste (Li et al. 2020). Aufgrund des höheren Niederschlags im Jahr 2021 war das Nav im Jahr 2021 mit einem mittleren Unterschied von ca. 160 kg Nav ha<sup>-1</sup> deutlich höher als 2022, aber auch regionale Unterschiede im Nav änderten sich zwischen den Jahren. Die folgenden Rangfolgen wurden für 2021 und 2022 gefunden: NWR > NR > MR und NR > MR > NWR. Im Jahr 2022 war das Nav in den Regionen NR, NWR und MR jeweils um 18%, 52% bzw. 27% niedriger im Vergleich zu 2021. Während in der Region NWR ein niedrigerer Ertrag von ca. 6.4 t TM ha<sup>-1</sup> im Jahr 2022 mit einem viel stärkeren Rückgang des Nav im Vergleich zu 2021 einherging, stieg die  $NUE_{DM}$  von 50.3 auf 97.8 kg TM kg<sup>-1</sup> Nav (Tabelle 8). In der Region M war der Rückgang des Ertrags von 2021 auf 2022 mit durchschnittlich 11.4 t TM ha<sup>-1</sup> viel höher als der entsprechende Rückgang des Nav, was zu einem Rückgang der  $NUE_{DM}$  von 83 auf 65 kg TM kg<sup>-1</sup> Nav von 2021 auf 2022 führte. Das vergleichsweise höhere Nav in der MR könnte auf die Futtergräser zurückzuführen sein, die 2021 als Vorfrucht angebaut wurden, was bekannt dafür ist, dass es Nav im Boden in den ersten zwei Jahren nach der Bodenbearbeitung drastisch erhöht (Cougnon et al. 2018). Außerdem befand sich der Versuchsort in der MR im Jahr 2021 nahe der Aue des Flusses Fulda, während 2022 ein Hangstandort gewählt werden musste. Die Nmin-Mengen werden zur Veranschaulichung in Abbildung S2 dargestellt.

#### *Genotypische Effekte auf die N-Nutzungseffizienz*

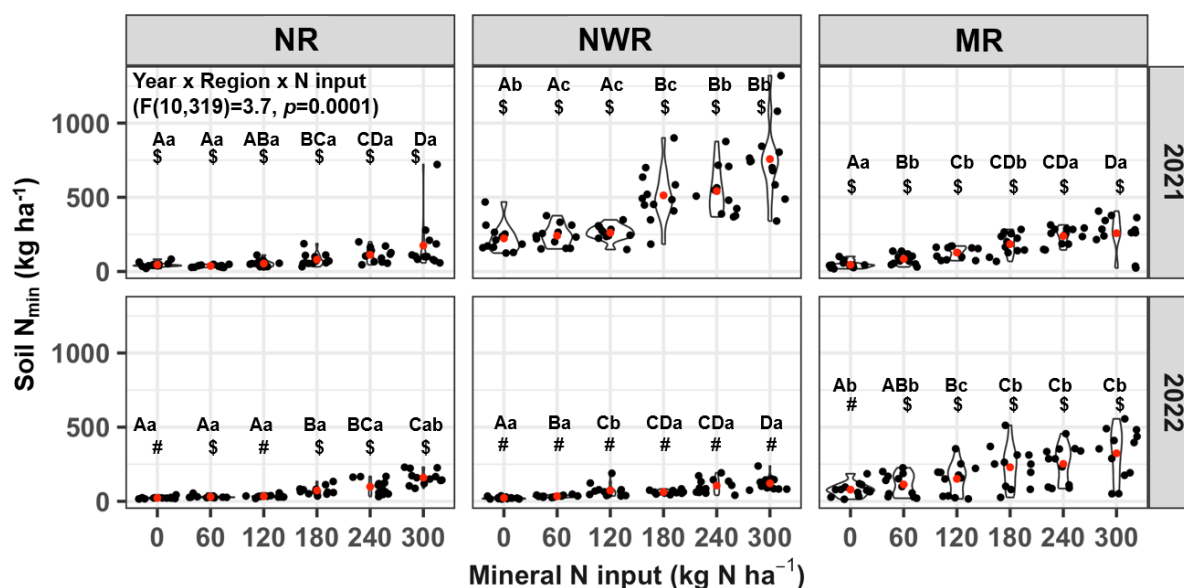
Laut Adeo et al. (2016) unterscheiden sich Mais-Hybriden in ihrer Trockentoleranz, und dieses Merkmal wird zunehmend wichtiger, wenn Umweltbedingungen bestimmte Hybriden begünstigen, indem entscheidende Entwicklungsphasen wie die Körnerfüllung in die Trockenheitsperiode fallen. Ke und Ma (2021) beobachteten zum Beispiel, dass später reifende Hybriden zu Ertragsverlusten durch Trockenheit neigen, wenn die Blüte und spätere Kornfüllungsphase von einer Spätsommertrockenheit betroffen ist. Das bedeutet, dass frühe oder mittlere Trockenperioden besser von späteren Hybriden kompensiert werden können, da in Zeiten von Wassermangel während des frühen oder mittleren Sommers (Juni-August) die Kornfüllung bei später reifenden Hybriden unter verbesserten Bodenfeuchtigkeitsbedingungen nach einer Wiederbefeuchtung erfolgt. Beim Vergleich der Niederschlagsverteilung bis August, zeigt sich, dass in unseren Feldversuchen die Trockenheit besonders in den vegetativen Wachstumsphasen ausgeprägt war. Der Unterschied im Ertrag und  $N_{up}$  zwischen S260 und den anderen Hybriden war im trockeneren Jahr 2022 deshalb stärker ausgeprägt, mit 2.6 bzw. 2.2 t TM ha<sup>-1</sup> bzw. 28 bzw. 19 kg N ha<sup>-1</sup> höherem  $N_{up}$  im Vergleich zu den Hybriden S210 und S250. Später reifende Hybride haben einen höheren Green-Area-Index (GAI) über einen längeren Zeitraum aufgrund eines längeren vegetativen Wachstums, was die Strahlungsabsorption und Strahlungsnutzungseffizienz verbessert. Laut Birch et al. (2003), die drei Mais-Hybriden mit unterschiedlichem Reifetempo in den Niederlanden testeten, haben später reifende Hybriden einen höheren maximalen GAI, der später in der Saison absinkt. Dadurch nutzen sie die verfügbare Temperatursumme und Strahlung effizienter zur Biomasseproduktion. Dies steht im Einklang mit Arriola et al. (2012), die Silomais-Hybriden in Zeiternten beprobten und einen um 3.4 t TM ha<sup>-1</sup> höheren Ertrag für Hybriden mit dem Stay-Green-Merkmal für längeres vegetatives Wachstum fanden. Bukowiecki et al. (2024) verwendeten Drohnen-basierte Daten, um Modelle zur Vorhersage des GAI zu entwickeln, die auch Daten der vorliegenden Experimente beinhalteten. Über die Saison hinweg erreichten S250 und S260 sehr ähnliche Werte und ähnliche maximale GAI. S260 zeigte jedoch einen verzögerten GAI aufgrund des späteren vegetativen Wachstums im Frühjahr, wenn die Strahlungsintensität noch nicht ihr Maximum erreicht hat und damit einen geringeren trade-off zwischen GAI und maximaler Strahlungsaufnahme bedeutet. Die langsamere Abreife im Spätsommer unter den Bedingungen noch eintreffender Einstrahlung ermöglichte schließlich eine höhere Strahlungsausnutzung, was die höheren Erträge erklärt und gut zu den höheren Erträgen von späterem Mais in früheren Studien passt (z.B. Arriola et al. (2012)).

#### **Schlussfolgerungen**

Die Hypothese, dass Maissorten aufgrund ihrer Abreifegeschwindigkeit unterschiedliche optimale N-Düngemengen benötigen und dass diese von den Umweltbedingungen abhängt, konnte nicht bestätigt werden. Die absolute N-Düngungshöhe war in der vorliegenden Untersuchung nicht von der angebauten Maisreifegruppe abhängig, da die Sorten sich nicht im Ertrag unterschieden. Für Bedingungen mit Frühsommertrockenheit erscheinen mittel-späte Sorten geeigneter, da die für den Ertrag entscheidende Phase der Kornfüllung nach der Trockenheit stattfindet. Zudem führt die verzögerte Abreife im Zuge der spätsommerlich hohen Einstrahlung zu einer höheren Strahlungsaufnahme zur Biomasseproduktion.

## Anhang

Der Boden-N<sub>min</sub>-Wert wurde durch die dreifache Wechselwirkung von Jahr x Region x N-Düngung beeinflusst ( $F(10,319)=317, p=0.0001$ ) (Abbildung S1). Der Boden-N<sub>min</sub>-Wert unterschied sich zwischen den Jahren, insbesondere in der Region NWR, mit im Durchschnitt signifikant 84% höheren N<sub>min</sub>-Werten im Jahr 2021 im Vergleich zu 2022. In dieser Region waren die N<sub>min</sub>-Werte im Jahr 2021 immer signifikant höher als in NR und MR. Im Gegensatz dazu waren die Unterschiede zwischen den Jahren in den Regionen NR und MR auf einige Ausnahmen beschränkt (Abbildung S1). Im Jahr 2022 waren die N<sub>min</sub>-Werte in MR meist höher als in NR und NWR. Generell war der Boden-N<sub>min</sub>-Wert bei N-Düngungsraten über N180 in NR und NWR signifikant höher als in der ungedüngten Kontrolle (N0). Nur in MR nahm der N<sub>min</sub>-Wert sofort mit jedem Anstieg der N-Düngung zu (Abbildung S1).



**Abbildung S 1. N<sub>min</sub>-Menge im Boden zur Maisernte (0-90 cm) in Abhängigkeit von Region, Jahr und N-Menge. Kleinbuchstaben zeigen signifikant unterschiedliche Mittelwerte zwischen den Regionen pro Jahr und N-Menge an, Großbuchstaben zeigen signifikante Unterschiede zwischen den N-Mengen pro Region und Jahr, und Symbole \$# zeigen signifikant unterschiedliche Jahre pro Region und N-Menge an ( $p<0.05$ ). Rote Punkte zeigen arithmetische Mittelwerte an. NR = Nord, NWR = Nordwest, MR = Mittlere Region.**

## Datenanalyse, Teil 3: Effizienz der organischen Düngung in Silomais (*Zea mays* L.) beeinflusst durch Trockenheit

### Zielstellung

Die kontrastierenden Umweltbedingungen – ein eher feuchtes und ein sehr trockenes Versuchsjahr - führten zur Frage, ob und in wie weit die Wirksamkeit organischer N-Düngung im Maisanbau durch diese Witterungsunterschiede beeinflusst wird. Eine daran angeschlossene Frage umfasste die N-Effizienz der organischen Düngung. Das Ziel ist demnach eine Gegenüberstellung der Effizienz von organischer und mineralischer Düngung in einer mittelfrühen Maissorte während sehr kontrastierenden Jahren.

### Ergebnisse

Die Varianzanalyse ergab, dass der Ertrag der Pflanzenbiomasse signifikant durch die Wechselwirkung von Jahr x Behandlung ( $p<0.001$ ) und durch den Haupteffekt Region ( $p<0.05$ ) beeinflusst wurde, wobei Behandlung sowohl N-Menge als auch N-Art zusammenfasst (Tabelle 9). Die Wechselwirkung von Region x Jahr x Behandlung war marginal signifikant ( $p<0.1$ ) (Tabelle 9). Der  $N_{up}$  wurde signifikant durch die Wechselwirkung von Region x Jahr x Behandlung beeinflusst ( $p<0.05$ ). Der Biomasseertrag und  $N_{up}$  werden daher zur Konsistenz unter Berücksichtigung dieser 3-fach Wechselwirkung dargestellt (Abbildungen 11, 12).

Tabelle 9. Die p-Werte der linearen gemischten Modelle für den Ertrag (t TM ha<sup>-1</sup>), die N-Aufnahme (N<sub>up</sub>, kg N ha<sup>-1</sup>), die physiologische Effizienz (PE, kg TM kg<sup>-1</sup> Nup), den Mineralstickstoff (Nmin) bei BBCH13 (Nmin<sub>start</sub>) und am Ende der Vegetationsperiode (Nmin<sub>end</sub>).

Effekte	Ertrag	N <sub>up</sub>	PE	NNI	Nmin <sub>start</sub>	Nmin <sub>end</sub>
Region (R)	p=0.048	p=0.191	p=0.636	p=0.460	p=0.290	p<0.0001
Jahr (Y)	p=0.0003	p=0.045	p=0.945	p=0.374	p=0.019	p=0.337
Behandlung (T)	p=0.083	p=0.046	p=0.044	p=0.177	p=0.022	p=0.084
R x Y	p=0.081	p=0.235	p=0.872	p=0.533	p=0.956	p=0.0003
R x T	p=0.683	p=0.721	p=0.738	p=0.903	p=0.849	p=0.008
Y x T	p=0.0002	p=0.0001	p=0.237	p=0.016	p=0.358	p=0.700
R x Y x T	p=0.087	p=0.011	p=0.341	p=0.143	p=0.960	p=0.584

Signifikante Unterschiede zwischen den Behandlungen wurden nur in der Region N festgestellt (Abbildungen 11 und 12). Der Ertrag und auch N<sub>up</sub> waren 2021 für N180min signifikant größer. Im Jahr 2022 hingegen wurden der höchste Ertrag und N<sub>up</sub> für N180org festgestellt, gefolgt von N60org (Abbildung 11, Abbildung 12). Eine weitergehende Betrachtung der im selben Zeitraum Drohnen-basiert erhobenen Green Area Index (GAI)-Verläufe zeigt, dass die GAI-Werte der N60org- in 2022 deutlich geringer waren als die der N60min-Variante. Das lässt einen zunächst vermuteten Düngefehler unwahrscheinlich werden. Die Betrachtung der über die Saison durchgeführten Zwischenernten zeigt, dass die N60org-Variante in beiden Jahren am Standort NR und auch am Standort MR in 2021 und am Standort NWR in 2022 eine deutlich bessere Frühentwicklung als die N60min-Variante. Das findet sich auch in den GAI-Verläufen wieder. Diese Standort- und Jahres-spezifischen Unterschiede in der Dynamik der Wirksamkeit der organischen Düngung sollen über das Ende des Projektes hin weiter untersucht werden.

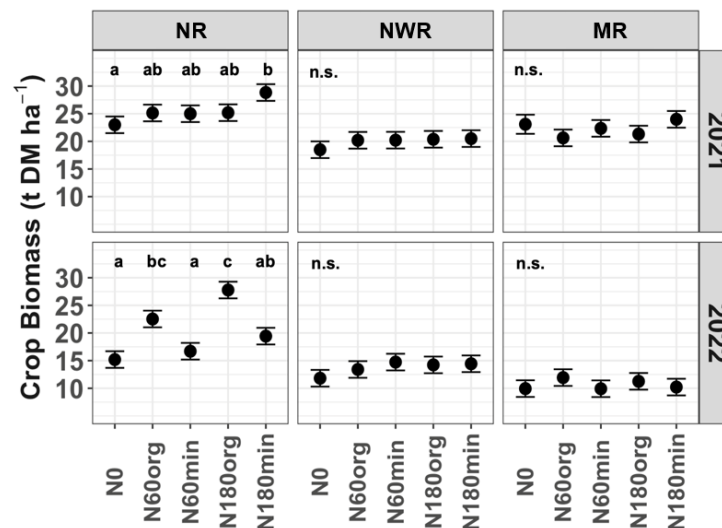


Abbildung 11. Geschätzte Mittelwerte ± SE des Ertrags (t TM ha<sup>-1</sup>), dargestellt für die Interaktion von Region-Jahr-Behandlung. Kleinbuchstaben zeigen signifikante Unterschiede zwischen den Behandlungen pro Region und Jahr (p<0.05). n.s. zeigt an, dass die Unterschiede nicht signifikant waren. NR = Nord, NWR = Nordwest, MR = Mitte.





Abbildung 12. Geschätzte Mittelwerte ± SE der Stickstoffaufnahme (kg N ha<sup>-1</sup>), dargestellt für die Interaktion von Region-Jahr-Behandlung. Kleinbuchstaben zeigen signifikante Unterschiede zwischen


den Behandlungen pro Region und Jahr ( $p < 0.05$ ). n.s. zeigt an, dass die Unterschiede nicht signifikant waren. NR = Nord, NWR = Nordwest, MR = Mitte.

Die PE lag zwischen 97.8 und 126.2 kg TM  $\text{kg}^{-1}$  N-Aufnahme, wobei ein signifikant niedrigerer Wert für N180min im Vergleich zu allen anderen Behandlungen gefunden wurde (Abbildung 13).



**Abbildung 13.** Geschätzte Mittelwerte  $\pm$  SE der physiologischen Effizienz ( $\text{kg TM kg}^{-1}$  N-Aufnahme) in Abhängigkeit von der Behandlung. Kleinbuchstaben zeigen signifikante Unterschiede zwischen den Behandlungen ( $p < 0.05$ ).

Der NNI wurde von der Wechselwirkung von Jahr  $\times$  Behandlung beeinflusst ( $p < 0.05$ ) (Tabelle 9). Vergleiche der Mittelwerte zeigten keine Unterschiede zwischen den Behandlungen in der Region M. N180min ergab den höchsten NNI, der einen Wert von 1 überschritt, in der Region N (Abbildung 14). Dort unterschieden sich die NNIs zwischen N180min und N180org nicht voneinander.



**Abbildung 14.** Geschätzte Mittelwerte  $\pm$  SE des Stickstoffernährungsindex (NNI), dargestellt für die Interaktion von Region-Jahr-Behandlung. Kleinbuchstaben zeigen signifikante Unterschiede zwischen den Behandlungen pro Region und Jahr ( $p < 0.05$ ). n.s. zeigt an, dass die Unterschiede nicht signifikant waren. NR = Nord, NWR = Nordwest, MR = Mitte.

Während  $N_{\text{min start}}$  vom Haupteffekt der Behandlung beeinflusst wurde ( $p < 0.05$ ) (Tabelle 9), wurde  $N_{\text{min end}}$  von den Wechselwirkungen Region  $\times$  Behandlung ( $p < 0.01$ ) und Region  $\times$  Jahr ( $p < 0.001$ ) beeinflusst (Tabelle 9). Vergleiche der Mittelwerte für  $N_{\text{min start}}$  ergaben signifikant höhere Werte für N180min im Vergleich zu N60org und N0 (Tabelle 10). Für  $N_{\text{min end}}$  wurden 2021 in der Region N keine Unterschiede zwischen den Behandlungen festgestellt (Tabelle 10). 2022 gab es in Region N eine schrittweise Zunahme von N0 bis N180min für  $N_{\text{min end}}$  (Tabelle 10). In NW führte N180min zu den höchsten  $N_{\text{min end}}$ -Werten, die signifikant höher waren als fast alle anderen Behandlungen (Tabelle 10).

**Tabelle 10.** Mineralische Boden- $N_{\text{min}}$  Menge ( $\text{kg ha}^{-1}$ ) bei BBCH 13 ( $N_{\text{min start}}$ ) und am Ende der Vegetationsperiode ( $N_{\text{min end}}$ ) in einer Bodentiefe von 0-90 cm in Abhängigkeit von der Behandlung

( $N_{min_{start}}$ ) oder der Wechselwirkung von Jahr-Region-Behandlung ( $N_{min_{end}}$ ). Kleinbuchstaben zeigen signifikante Unterschiede innerhalb der Zeile ( $p < 0.05$ ).

Zeitpunkt	Jahr	Region	N0	N60org	N60min	N180org	N180min
$N_{min_{start}}$			104 ± 9.0 a	134 ± 13.1 ab	167 ± 8.6 bc	155 ± 9.4 bc	223 ± 24.6 c
$N_{min_{end}}$	2021	N	45.8 ± 7.0 a	41.1 ± 3.7 a	39.3 ± 5.3 a	38.7 ± 4.6 a	57.7 ± 6.7 a
	2021	NW	248.5 ± 45.8 ab	189.2 ± 19.4 a	241.1 ± 35.6 a	233.9 ± 25.8 a	405.6 ± 42.4 b
	2022	N	37.2 ± 6.3 a	42.0 ± 3.7 a	42.5 ± 5.5 ab	45.2 ± 4.9 ab	62.7 ± 7.0 b
	2022	NW	45.6.7 ± 19.6 ab	61.1 ± 11.0 a	55.5 ± 14.8 a	75.6 ± 14.7 ab	140.6 ± 28.7 b

## Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais

Im Rahmen der Feldversuche in AP1 wurden umfangreiche UAV-Befliegungen durchgeführt. Ziel war, in einem ersten Schritt den verwendeten Spektralsensor (Parrot Sequoia™) auf die Bestandesparameter Green Area Index (GAI) und N-Aufnahme zu kalibrieren. Im nächsten Schritt sollten die Kalibrationen genutzt werden um zeitlich hochaufgelöste (2-wöchentl. Befliegungsrhythmus) Verläufe dieser Bestandesparameter zu generieren. Außerdem wurde auf dem Standort der CAU eine UAV-basierte Thermalkamera (DuetT) eingesetzt um über die Bestandestemperatur Aussagen über den herrschenden Trockenstress zu generieren.

### Arbeitspaket 2, Teil 1: Vegetationsbegleitende Befliegung der Parzellen mit 4-Kanalspektralkameras und Infrarotkameras

Die Befliegungen an der CAU erfolgten wie vorgesehen. Beim Feldversuch des LLHs und der GAUG führten Verzögerungen bei der Technikanschaffung zu fehlenden Befliegungen zu Beginn der Saison 2021. Zudem erfolgten zu Beginn der Saison 2022 am Standort der GAUG keine Befliegungen. Die erhobenen Spektraldaten wurden wie vorgesehen an der CAU zusammengeführt und ausgewertet. In beiden Versuchsjahren wurden an der CAU über die gesamte Saison hinweg regelmäßig Befliegungen mit dem Thermalsensor durchgeführt (ab Juni bis Ernte, jeweils neun Befliegungen).

### Arbeitspaket 2, Teil 2: Ableitung von Regressionsmodellen zur Schätzung von Bestandesparametern, insbesondere der N-Aufnahme aus 4-Kanal, UAV-basierten Reflektionskarten; Validierung der Modelle an unabhängigen Daten

Daten von Feldversuchen eines früheren CAU-Projektes (THGZwiFru) und eines aktuellen CAU-Projektes (RootWayS) konnten zur Erweiterung des aus AP1 zur Verfügung gestellten Datensatzes genutzt werden. Durch die Verzögerung bei der Analyse der N-Konzentrationen der Pflanzen konnte mit der Auswertung in Richtung eines Regressionsmodells für die N-Aufnahme erst verzögert begonnen werden. Der Datensatz für die Kalibration eines Modells für die N-Aufnahme umfasst 1986 Datenpunkte, erhoben durch 35 Befliegungen in vier Jahren und auf insgesamt drei Standorten. Der GAI-Datensatz enthält 952 Datenpunkte, mit 20 Befliegungen in vier Jahren auf zwei Standorten (in den GAUG-Feldversuchen wurde kein GAI erfasst).


Der eingesetzte Spektralsensor Parrot Sequoia™ erfasst bei jeder Aufnahme vier verschiedene Reflexionsbereiche (Grün, Rot, Red Edge (RE), Nahes Infrarot (NIR)). Alle möglichen Kombinationen dieser Bänder wurden im Hinblick auf ihre Beschreibungsgüte für die N-Aufnahme und den GAI geprüft. Hierfür wurde der Datensatz in einen unabhängigen Kalibrations- und Evaluationsdatensatz aufgeteilt. Es wurde ein Methodenkatalog entwickelt, der sich problemlos für die Kalibration weiterer Parameter bzw. anderer Kulturen nutzen lässt. Zudem wurde analysiert, ob es einer Silomais-spezifischen Kalibration des Spektralsensor bedarf, oder ob eine gemeinsame Kalibration für Silomais, Winterweizen, Wintergerste und Winterraps verwendet werden kann. Die hierfür zusätzlich genutzten Daten stammten aus früheren Feldversuchen der CAU (Tabelle 111).

**Tabelle 11: Überblick über den für die Kalibration der UAV-basierten Multispektraldaten auf Silomais-Bestandesparameter genutzten Daten (GAI: Green Area Index, CAU: Versuchsstandort der CAU in Schleswig-Holstein, GAUG: Versuchsstandort der GAUG in Niedersachsen, LLH: Versuchsstandort des LLHs in Hessen).**

Bestandesparameter	n <sub>Kalibration</sub>	n <sub>Evaluation</sub>	n <sub>Beprobungstermine</sub>	Versuchsstandorte und Jahre
GAI [m <sup>2</sup> m <sup>-2</sup> ]	549	493	20	CAU/2019–2022 LLH/2022
N-Aufnahme bis Blüte [g m <sup>-2</sup> ]	485	477	18	CAU/2019–2022 GAUG/2022 LLH/2021, 2022

Die Auswertung ergab, dass eine Silomais-spezifische Kalibration (Formel 4) einer Kulturarten-übergreifenden Kalibration überlegen ist. Zum Vergleich: das Silomais-spezifische GAI-Modell erbrachte in der Evaluation einen relativen mittleren absoluten Fehler (rMAE) von 17 % (Abbildung 15), das Kulturarten-übergreifende Modell hingegen von 24 %. Dieser höhere Fehler kann auf eine deutliche Unterschätzung hoher GAI-Werte zurückgeführt werden. Der Mehrwert einer extra Kalibration für Silomais lässt sich unter anderem darauf zurückführen, dass N-Mangel im Silomais im Kontrast zu den anderen untersuchten Kulturen statt der Blattfläche die N-Konzentration in den Blättern reduziert. Hierdurch ergibt sich bei schlechten etablierten Beständen kein höherer Reflektionsanteil des Bodens. Dieses Verhalten zeigte sich in einer anderen Wertigkeit der getesteten Reflektionsbänder und ihrer Kombinationen für die Beschreibung der N-Aufnahme und des GAI.

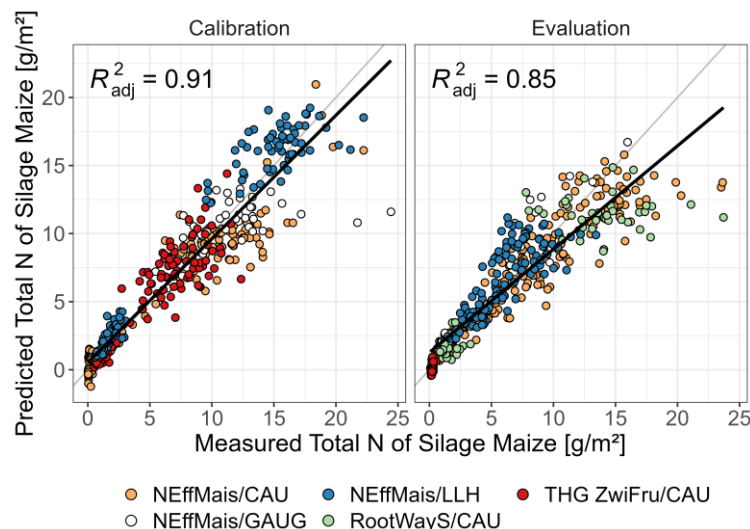
$$GAI = 0.639102 + 0.59338 \times \frac{NIR}{Grün} - 0.001463 \times \left(\frac{NIR}{Red}\right)^2 - 5.839889 \times \frac{Rot}{RE} + 4.745498 \times \left(\frac{Rot}{RE}\right)^2 \quad (4)$$



**Abbildung 15: Zusammenhang zwischen destruktiv erhobenem und mittels der UAV-Kalibration berechnetem ganzsaisonalen GAI.**

Bereits relativ früh in der Auswertung zeigte sich, dass keine ganzsaisonale Kalibration für die N-Aufnahme von Silomais möglich ist. Eine weiterführende Analyse zeigte, dass die Blüte der späteste Zeitpunkt in der Saison ist, bis zu dem dieser Parameter UAV-basiert beschrieben werden kann (Formel 5). Der rMAE der Evaluation für das bis zu diesem Zeitpunkt kalibrierte Modell beträgt 23 % (= 1.39 g/m<sup>2</sup>, Abbildung 16). Weitere Ergebnisse, sowie eine detailliertere Beschreibung der Methoden und eine umfangreiche Diskussion der Ergebnisse können in Bukowiecki et al. (2024) nachgelesen werden.

$$N\text{-Aufnahme} \left[\frac{g}{m^2}\right] = 19.60863 + 3.25923 \times \frac{NIR}{Grün} - 0.01573 \times \left(\frac{NIR}{Red}\right)^2 + 39.59739 \times \left(\frac{Green}{RE}\right) - 28.90509 \times \left(\frac{Green}{RE}\right)^2 \quad (5)$$



**Abbildung 16: Zusammenhang zwischen destruktiv erhobener und mittels der UAV-Kalibration berechneter N-Aufnahme bis zur Blüte.**

### Arbeitspaket 2, Teil 3: Prüfung der Anwendbarkeit in Parzellen im Hinblick auf zeitliche und variantenspezifische N-Aufnahme

Die Befliegungen auf den Versuchen der CAU erfolgten in beiden Versuchsjahren wie vorgesehen im zweiwöchentlichen Rhythmus. Auf deren Basis und mittels der erstellten UAV-Kalibrationen konnten zeitlich hochaufgelöste ganzsaisonale GAI-Verläufe und N-Aufnahmen bis zur Blüte für 2021 und 2022 berechnet werden (Abbildung 17, Abbildung 18). Die bereits beschriebenen Lücken im zweiwöchentlichen Befliegungsrhythmus am LLH in 2021 und an der GAUG in beiden Jahren führen zu unvollständigen Bestandesparameter-Verläufen (Abbildung 17, Abbildung 18).

Trotz dieser Einschränkungen konnte durch die Arbeiten im Rahmen von NEffMais die UAV-Technik als effiziente und präzise Methode zur Erhebung von Bestandesinformationen im Silomais auf allen drei Standorten demonstriert werden. Mittels dieser Methodik können sowohl Bestandesunterschiede durch unterschiedliche N-Düngung (Abbildung 17) wie auch Sortenunterschiede (Abbildung 18) über die gesamte Saison analysiert werden. Die so generierten Verläufe wurden an AP5 übergeben.

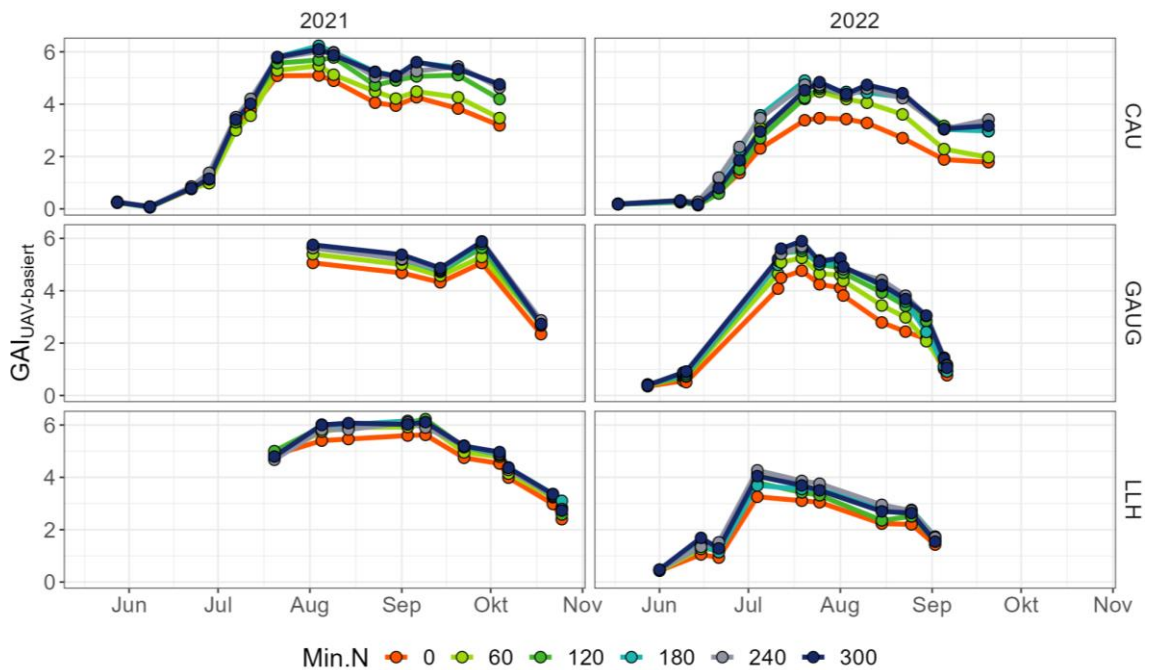


Abbildung 17: UAV-basiertes GAI-Monitoring in den zweijährigen Feldversuchen an den drei Standorten. Dargestellt sind die Mittelwerte der rein mineralisch gedüngten Parzellen über alle drei Sorten.


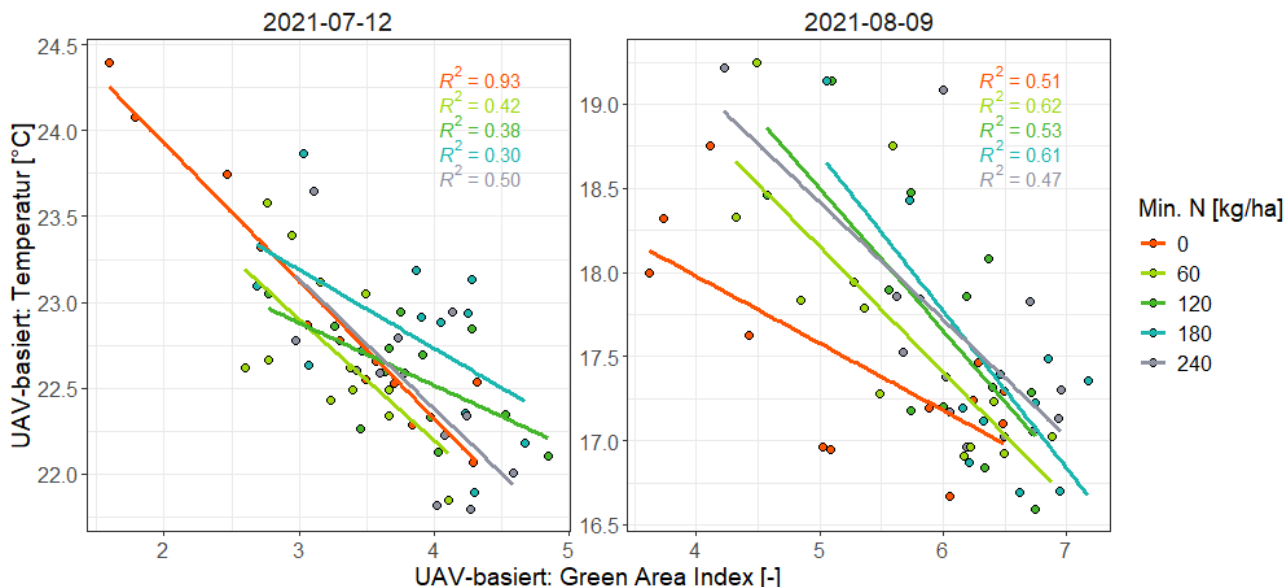


Abbildung 18: UAV-basiertes GAI-Monitoring in den zweijährigen Feldversuchen an den drei Standorten. Dargestellt sind für jede Sorte (drei verschiedene Reifegruppen) die Mittelwerte über alle rein mineralisch gedüngten Parzellen.


### Arbeitspaket 2, Teil 4: UAV-basierte Thermaldaten

In 2021 war über die gesamte Saison kein deutliches Stress-Signal erkennbar. Allerdings wurden im Juli und August wärmere Bestandestemperaturen bei gleichem Green Area Index bei höher gedüngten Varianten gefunden (Abbildung 19). Das könnte die Folge des niedrigeren Wasserbrauchs der ungedüngten Varianten bis zu diesem Zeitpunkt sein, denen in Folge im späteren Verlauf der Saison mehr Wasser zu Verfügung steht. Bei dauerhaft ausbleibenden Niederschlägen könnten die ungedüngten Varianten so länger ohne Wasserbedingte Einschränkungen Photosynthese betreiben und Düng-induzierte Nachteile kompensieren. Das würde zu den Beobachtungen beim LLH im Jahr 2022 passen, wo es zur Ernte kaum eine Trockenmasse-reaktion auf die gestaffelte N-Düngung gab.



**Abbildung 19: Korrelation von UAV-basiert erfasstem Green Area Index und Temperatur an zwei verschiedenen Terminen der Saison 2021 am CAU-Versuchsstandort, gruppiert nach mineralischer N-Düngung.**

Während einer für den Standort außergewöhnlich warmen und trockenen Phase im Juli 2022 wurden zusätzlich Unterschiede in der Bestandestemperatur erfasst, die sich nicht auf die N-Varianten oder Sorten zurückführen lassen (Abbildung 20). Vielmehr scheint in einzelnen Bereichen des Versuches die Wasserverfügbarkeit eingeschränkter gewesen zu sein, was in im Vergleich höheren Bestandestemperaturen resultiert. Dies könnte ein Indikator für im Versuch variierende Bodentexturen sein. Einen zusätzlichen Effekt könnte die Versuchsausrichtung und damit die Einfallrichtung der Sonne in den Bestand gehabt haben. So war an diesem und an anderen, nicht dargestellten Terminen, die gemessene Bestandestemperatur im Süd-Westen der Parzellen höher als im Nord-Osten.



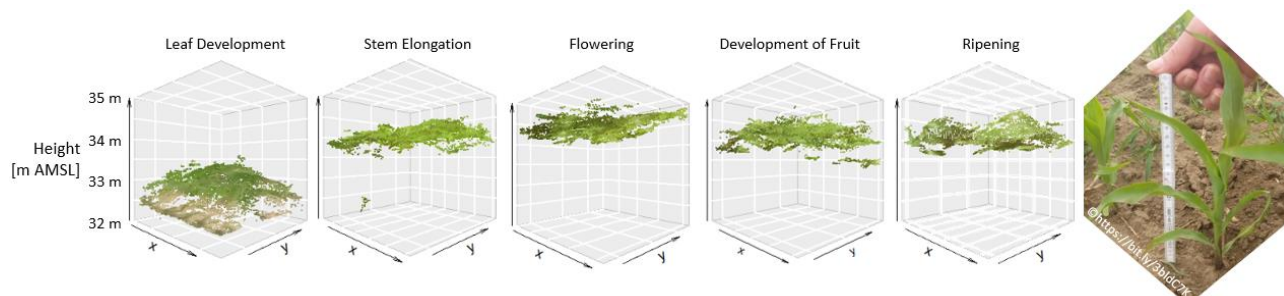
**Abbildung 20: UAV-basiert gemessene Bestandestemperatur am 25.07.2022 auf dem CAU-Versuchsstandort.**

### Arbeitspaket 2, Teil 5: Weitere Betrachtungen

Neben der nun multispektral erfassbaren photosynthetisch aktiven Fläche und ihrer transpiratorischen Aktivität, deren Erfassung mittels Thermalsensorik getestet wurde, ist das Niveau und die Variabilität der Bestandeshöhe ein wichtiger Parameter für die Betrachtung der Bestandstranspiration. Daher wurde

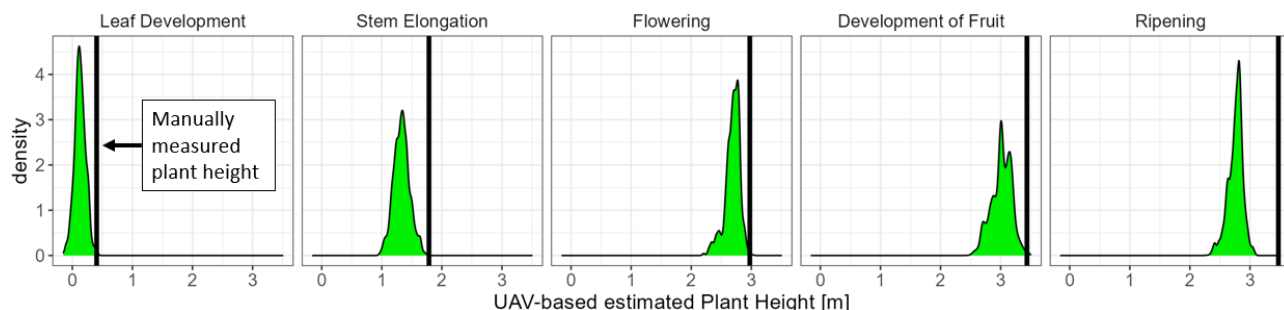
untersucht, ob bei der Befliegung mit dem Thermalsensor DuetT automatisch die mit erhobenen hochaufgelösten rgb-Daten (1.7·1.7 cm<sup>2</sup>) genutzt werden können, um diese Bestandesparameter zu erheben.

Hierfür wurden neben den UAV-Daten in beiden Saisons am CAU-Standort während der fünf destruktiven Beprobungen die Höhe der beprobten Pflanzen als Distanz zwischen Geländeoberkante bis zu höchsten Punkt des voll entfalteten Blatts gemessen. In pix4D wurden aus den rgb-Daten der Befliegungen vor der Beprobung 3D-Punktwolken mit bekannter Höhe über dem Meereslevel generiert (Abbildung 21). Die Lage der Beprobungsstellen wurde dabei über eine der über die Saison kontinuierlich erstellen Multispektralkarten bestimmt, auf denen man die Lücken im Bestand deutlich erkennen konnte.

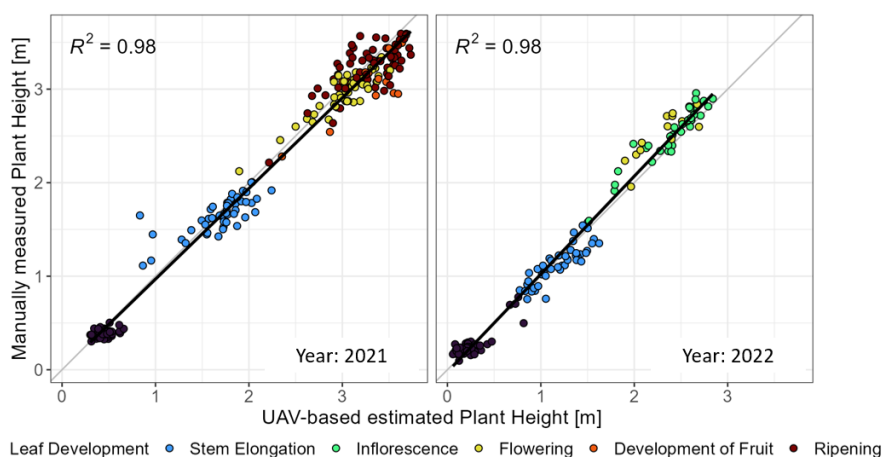


**Abbildung 21 (links): Für die Beprobungsstellen in einer Parzelle in 2021 generierte Punktwolken und (rechts) die Messung der Bestandeshöhe.**

Die Höhe über dem Meereslevel wurde im Anschluss auf eine absolute Bestandeshöhe umgerechnet. Hierfür wurde auf der Grundlage eines vor Bestandesauflaufen durchgeführten Fluges eine hochaufgelöste rgb-Karte vom Versuch erstellt und der für die Beprobungsstellen erfasste Mittelwert der Höhe über dem Meereslevel zum Standardisieren der Bestandeshöhen genutzt. In einem nächsten Schritt wurde untersucht, inwiefern die mittels Drohne erfasste Bestandeshöhe mit den gemessenen Pflanzhöhen zusammenhängt. Es zeigte sich, dass die Pflanzhöhen am ehesten zu der maximal auf einer Beprobungsstelle erfassten Bestandeshöhe passen (Abbildung 22). Das passt zu den Erwartungen – da die Bestandeshöhe sich aus einem Zusammenspiel aus der maximalen Pflanzhöhe (= manuell gemessen), der Höhe der restlichen Pflanzenorgane (z.B. zweithöchstes Blatt) und Lücken im Bestand zusammensetzt. Basierend auf diesem Resultat wurden im Anschluss die UAV-basiert erfassten Maxima pro Beprobungsstelle extrahiert um ihre Beschreibungsgüte für die manuell erfasste Pflanzhöhe zu testen. Es zeigte sich eine über beide Versuchsjahre und alle Beprobungstermine sehr enge Korrelation (Abbildung 23).



**Abbildung 22: Dichteplots der für die Beprobungsstellen in einer Parzelle in 2021 exemplarisch generierten Punktwolken.**



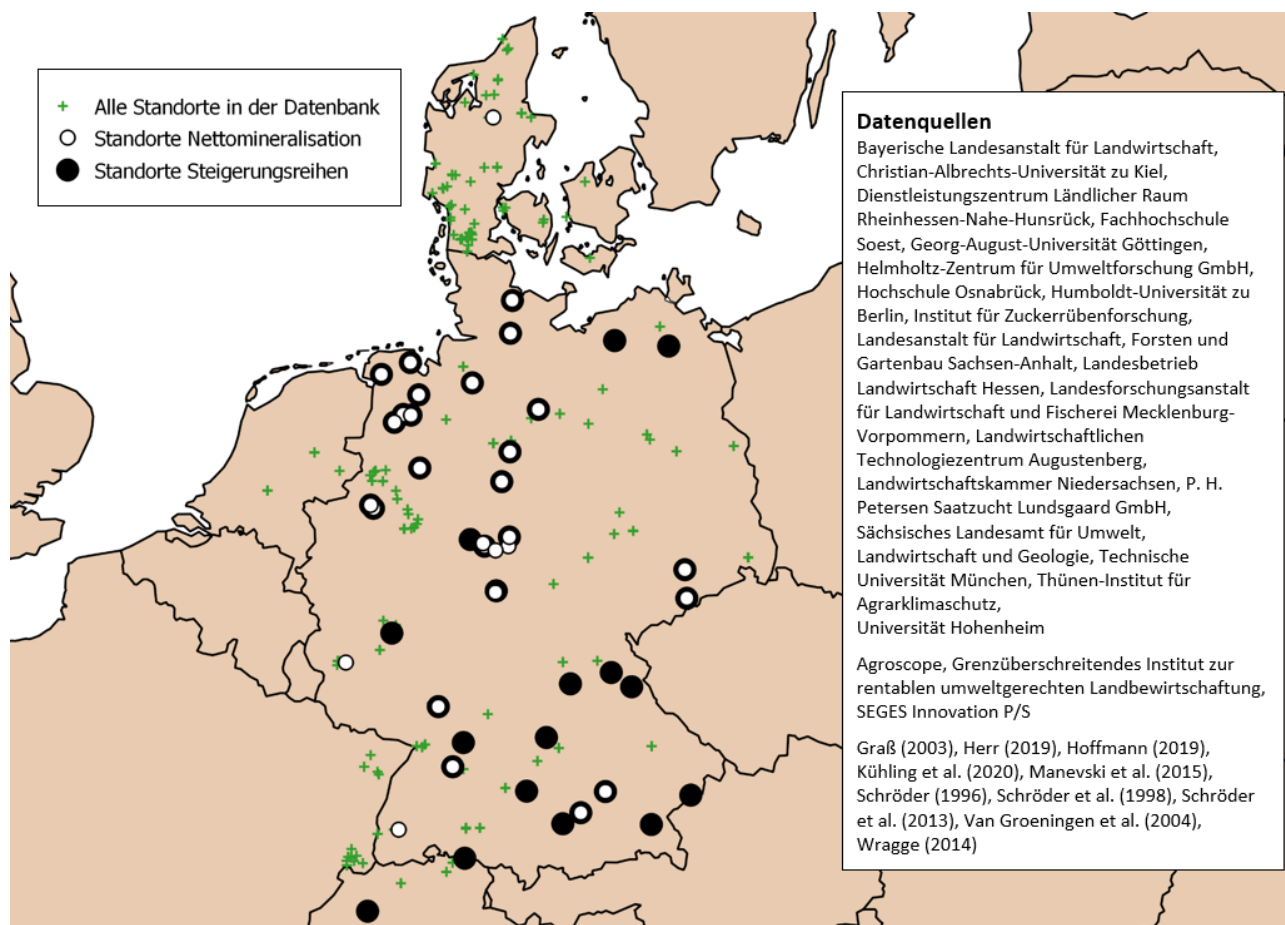
**Abbildung 23: Korrelation von UAV-basiert erfasster Pflanzhöhe und manuell gemessener Pflanzhöhe am Versuchsstandort der CAU.**

### Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation

Die Ziele von AP3 waren die Erstellung einer Silomais-Datenbank und die darauf basierende Entwicklung von Regressionmodellen für die standort- und jahresspezifische Abschätzung der ökonomisch optimalen N-Düngemenge (Nopt) und der N-Nettomineralisation. Vorgelagerte Fragestellung für die Nopt-Analyse war, welcher Funktionstyp sich am besten zur Abbildung des Zusammenhangs von Trockenmasse-Ertrag und N-Angebot im Silomais eignet.

#### Arbeitspaket 3, Teil 1: Aufbau einer Datenbank mit bundesweiten Ergebnissen und Randbedingungen von Stickstoffdüngungssteigerungsversuchen zu Silomais

Die Fertigstellung der Datenbank war bereits für das erste Projektjahr vorgesehen. Jedoch war die online-Datenrecherche aufwändiger und die Datenbereitstellung durch die verschiedenen Landesämter dauerte deutlich länger als zu erwarten. Erst im dritten Quartal 2023 konnte die Datenbank finalisiert werden. Abbildung 24 gibt eine Übersicht über die in der Datenbank enthaltenen Standorte und eine Liste der Datenquellen. Die Datenbank umfasst insgesamt 5355 Datenpunkte (Parzellen gleicher Variante wurden in einem Mittelwert zusammengefasst), mit 458 Jahr/ Standort-Kombinationen aus dem Zeitraum von 1988-2023.



**Abbildung 24: In der Silomais-Datenbank enthaltene Standorte, Nutzbarkeit für die Analysen im Hinblick auf Nopt (= Steigerungsreihen) und die N-Nettomineralisation und Übersicht über die Datenbereitsteller.**

Bodeninformationen und Klimadaten wurden aus Online-Archiven bezogen; für deutscher Standorte aus der Bodenübersichtskarte (BÜK200, <https://geoportal.bgr.de/>) und mittels an der CAU-entwickelten Schnittstellen zu Stationsdaten des Deutschen Wetterdienstes (DWD). Für ebenfalls in der Datenbank enthaltene Standorte in Dänemark und in der Schweiz wurden Bodeninformationen von der nächstliegenden online verfügbaren Bodenkartierung (Dänemark: <http://www.difgeodata.dk>, Schweiz: <https://www.nabodat.ch>) bzw. Wetterstation genutzt (Dänemark: [www.tutiempo.net](http://www.tutiempo.net), Schweiz: [www.infoclimat.fr](http://www.infoclimat.fr)).

#### Arbeitspaket 3, Teil 2: Schätzung vom Düngungsoptimum mit einheitlicher Methodik

Auf der Basis der gesamten Datenbank wurden für die Nopt-Analyse notwendige Annahmen hergeleitet: In der landwirtschaftlichen Praxis werden nur 90 % der in Parzellenversuchen erzielten Erträge erreicht (Parzellenfaktor = 0.8). Zudem ist ein Zuchtfortschritt von 1.3 dt/ha/Jahr festzustellen, um den die Trockenmasseerträge bereinigt wurden. Es kann von einem durchschnittlichen Trockensubstanz-Gehalt von 35 % im Erntegut ausgegangen werden. Lag für einen Standort kein Frischmasse-Ertragsniveau vor, wurde dieses aus den in diesem Jahr auf dem Feldversuch erzielten Trockenmasseerträgen geschätzt (Median der Trockenmasseerträge, korrigiert um Zuchtfortschritt, mittels durchschnittlichem Trockensubstanz-Gehalt in

Frischmasse umgerechnet). Zudem wurde für die Berechnungen ein Stickstoffpreis von 1.5 €/ kg N und ein Silomais-Preis von 47 €/t Frischmasse angenommen. Im Falle einer nicht rein mineralischen N-Düngung wurde die mittels organischer Düngung applizierte N-Menge entsprechen der Vorgaben der derzeit gültigen Düngeverordnung (DüV 2017) angerechnet.

Es wurden drei verschiedene N-Responsefunktionen zur Abbildung des Zusammenhangs von Trockenmasse-Ertrag und N-Angebot im Silomais getestet: quadratisch (q, Formel 6), quadratisch-plateau (qp, Formel 7) und linear-plateau (lp, Formel 8):

$$q: Y(N) = a \times N^2 + b \times N + c \tag{6}$$

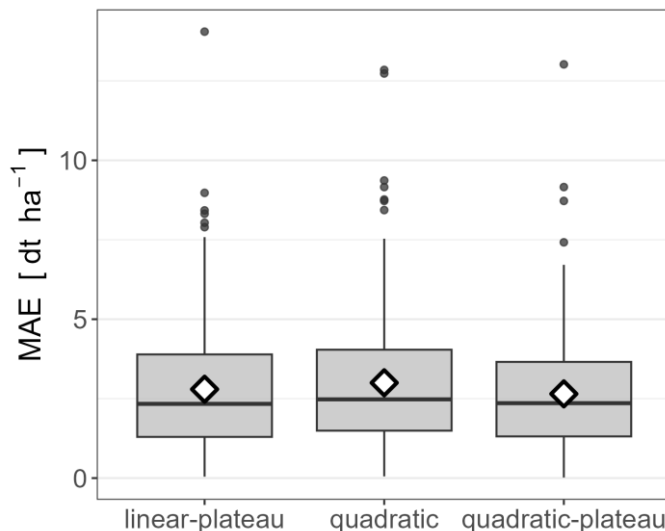
$$qp: Y(N) = \begin{cases} a \times (N - N_{max})^2 + Y_{max}; & N \leq N_{max} \\ Y_{max}; & N > N_{max} \end{cases} \tag{7}$$

$$lp: Y(N) = \begin{cases} a \times (N - N_{max}) + Y_{max}; & N \leq N_{max} \\ Y_{max}; & N > N_{max} \end{cases} \tag{8}$$

wobei Ymax der maximale Ertrag und Nmax das zum Erreichen von Ymax notwendige N-Angebot ist. Das N-Angebot ergibt sich dabei aus der Summe von N-Düngung und NminAussaat.

Zur Ableitung der Nopt-Werte wurden nur Daten aus N-Steigerungsversuchen verwendet, in denen mindestens 4 N-Varianten mit ansonsten gleichen Bedingungen (Düngeform, Maissorte, Vorfrucht, etc.) vorlagen. Zudem musste ein Anzeichen für einen abnehmenden Ertragszuwachs bei hoher N-Düngung vorhanden sein (quadratischer Term des q-Modells < 0) und alle drei getesteten Modelle mussten konvergieren und für die Steigerungsreihe plausible Ergebnisse (N-Düngeoptimum und N-Angebotsoptimum > 0) liefern.

Auf der Basis von 244 Steigerungsreihen von 131 verschiedenen Jahr/ Standort-Kombinationen zeigte sich, dass die qp-Funktion die Ertrags-Response von Silomais am besten abbildet (Abbildung 25). Ihr absoluter Fehler (MAE) lag im Median bei 2.7 dt/ ha, im Vergleich dazu lag der MAE der lp-Funktion bei 2.8 dt/ha und der der q-Funktion bei 3.0 dt/ha. Daher wurde zur späteren Regressionsmodellierung die mit der qp-Funktion ermittelten Nopt's verwendet. Die mit den drei Responsefunktionstypen berechneten Nopt's unterschieden sich dabei deutlich: die lp-Funktion lag im Mittel bei 117.4 kg N·ha<sup>-1</sup>, die qp-Funktion bei 125.1 kg N·ha<sup>-1</sup> (+5.5%), und die q-Funktion bei 141.2 kg N·ha<sup>-1</sup> (+20.3%). Die bei Nopt erreichten Trockenmassen unterschieden sich hingegen kaum, wobei die q-Funktion die höchsten Erträge mit 1.9 Mg·ha<sup>-1</sup> ausgab, die qp-Funktion nur 0.02 Mg·ha<sup>-1</sup> weniger.



**Abbildung 25: Mittlerer absoluter Fehler (MAE) der 244 getesteten Steigerungsreihen mit den drei unterschiedlichen getesteten N-Responsefunktionen.**

Die Nettomineralisation lässt sich hierfür aus der Differenz von N-Ertrag und N-Düngung berechnen, abzüglich der Differenz zwischen mineralischen Stickstoff im Boden in der Tiefe 0-90 cm zur Aussaat (NminAussaat) und zur Ernte (NminErnte).

### Arbeitspaket 3, Teil 3: Schätzung der Stickstoffmineralisation mit einheitlicher Methodik

Die Netto-N-Mineralisierung ist ein Maß für die N-Freisetzung aus dem Boden während der Wachstumsperiode. Sie repräsentiert die Mineralisierung von organischem N abzüglich der Immobilisierung von mineralischem N. Die Berechnung erfolgte empirisch mittels einer Massenbilanzmethode (Formel 9), in Anlehnung an Engels und Kuhlmann (1993) und Schröder (1999):

$$\text{Netto} - N - \text{Mineralisierung} = (N - \text{Ertrag} + N_{\text{min}_{\text{Ernte}}}) - (N_{\text{min}_{\text{Aussaat}}} + N - \text{Düngung}) \quad (9)$$

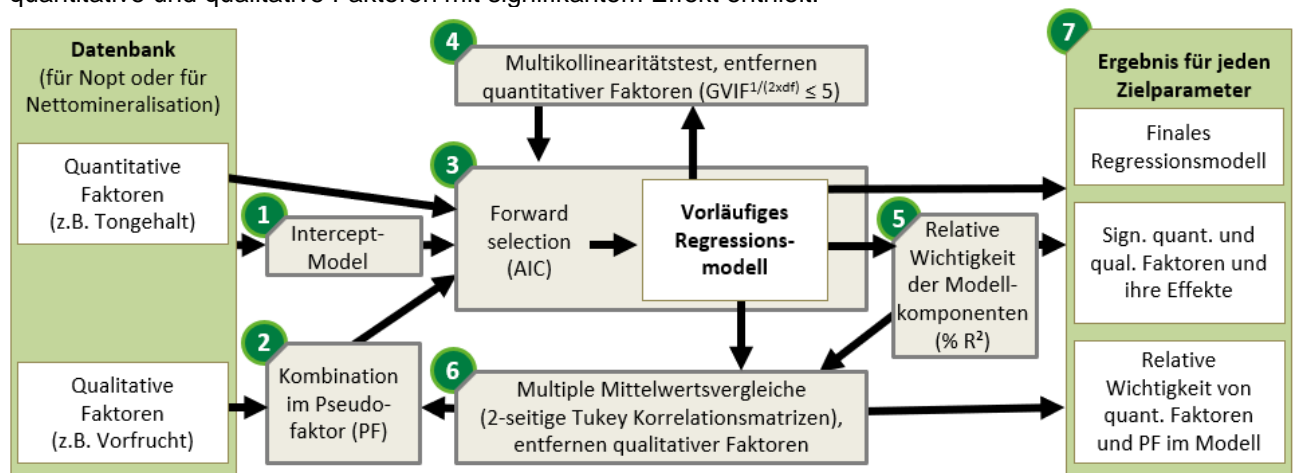
Dabei steht  $N_{\text{min}}$  für den Gehalt an mineralischem Bodenstickstoff in  $\text{kg ha}^{-1}$ , gemessen zur Aussaat ( $N_{\text{min}_{\text{Aussaat}}}$ ) und zur Ernte ( $N_{\text{min}_{\text{Ernte}}}$ ) in einer Bodentiefe von 0 bis 90 cm. Wenn Daten auf Parzellenebene und unter Einbeziehung verschiedener Behandlungen vorlagen, wurden diese als Durchschnitt pro Behandlung aggregiert. Der N-Ertrag wurde berechnet, indem der Proteingehalt durch 6.25 dividiert und mit dem Trockenmasseertrag der gesamten geernteten Pflanze multipliziert wurde (ISO 16634-2). Im Falle einer nicht rein mineralischen N-Düngung wurde die mittels organischer Düngung applizierte N-Menge entsprechen der Vorgaben der derzeit gültigen Düngeverordnung (DüV 2017) angerechnet.

### Arbeitspaket 3, Teil 4: Ableitung von Regressionsmodellen der Abhängigkeit der Stickstoffnetton mineralisation und des N-Düngungsoptimums von Standort- und Witterungsparametern

Zur Entwicklung eines Regressionsmodell für das Nopt und für die N-Netton mineralisation wurde dasselbe mehrstufige Auswertungsverfahren in R (R Core Team 2022) genutzt (Abbildung 26):

In einem ersten Schritt wurde auf der Basis aller vorliegenden Daten ein Mittelwertmodell, genannt Intercept-Model, geschätzt. Im Anschluss wurden sämtliche getesteten qualitative Faktoren in einem Pseudofaktor zusammengeführt. Dieser und alle getesteten quantitativen Faktoren wurden im nächsten Schritt in einem forward selection-Prozess, startend mit dem Intercept-Model, auf ihren Beitrag für das jeweilige Regressionsmodell geprüft (Ripley et al. 2024). Um eine Überparametrisierung zu vermeiden wurde zwischen den Faktoren keine Interaktionen getestet – zwei Bodenparameter und ein Witterungsparameter hätten eine Standort/Jahr-Kombination sehr genau abgrenzen können. Das Modell mit dem kleinsten Akaike-Informationskriterium (Akaike 2011) wurde als das beste ausgewählt (das Akaike Informationskriterium wichtet die Erkenntniszunahme in einem Modell durch die Hinzunahme eines Parameters gegen die steigende Modellkomplexität). Das ausgewählte Modell enthielt den Pseudofaktor und alle signifikanten ( $p < 0.05$ ) quantitativen Faktoren.

Die Nutzung verschiedener Witterungs- und Bodenparameter hätte zu einem Multikollinearitätsproblem führen können. Um dies zu testen wurde mit dem „car“-package (Fox und Weisberg 2019) der  $\text{GVIF}^{1/(2+\text{df})}$  berechnet. Es wurden solange Faktoren aus dem Modell entfernt, bis sämtliche Faktoren unter dem gewählten Grenzwert  $\text{GVIF}^{1/(2+\text{df})} \leq 5$  (Fox und Monette 1992) lagen. Von diesen Faktoren und dem Pseudofaktor wurde der prozentuale Anteil am  $R^2$  des Regressionsmodell bestimmt (Grömping 2006). Multiple Mittelwertvergleiche mit zweiseitige Korrelationsmatrizen nach Tukey (Hothorn et al. 2016) wurden durchgeführt um den Effekt der im Pseudofaktor zusammengefassten Faktoren zu beurteilen. Hatte eine Komponente des Pseudofaktors keinen signifikanten Effekt auf das Nopt bzw. die N-Netton mineralisation wurde sie aus dem Pseudofaktor entfernt und erneut der forward selection-Prozess gestartet. Hatten zwei oder mehr Komponenten des Pseudofaktors keinen signifikanten Effekt, wurden zum Vergleich eine entsprechende Anzahl an Regressionsmodell aufgestellt, bei deren Pseudofaktor jeweils eine dieser Komponenten entfernt wurde. Im Anschluss wurde der prozentuale Anteil des Pseudofaktor an der Erklärungsgüte des Regressionsmodell bestimmt. Das Modell bei dem der Pseudofaktor den größten Erklärungsanteil hat wurde übernommen. Die Reduktion des Pseudofaktor wurde so lange fortgeführt, bis das finale Regressionsmodell ausschließlich quantitative und qualitative Faktoren mit signifikantem Effekt enthielt.



**Abbildung 26: Mehrstufiges Auswertungsverfahren zur Ermittlung signifikanter Standort- und Management-Effekte auf das N-Düngeoptimum bzw. die N-Netton mineralisation.**

Sämtliche getesteten qualitativen Faktoren sind Managementoptionen:

- Vorfrucht; eingeteilt in die Kategorien Sommerbrache, Getreide (gedroschen), Getreide (Ganzpflanzenernte), Blattfrucht (gedroschen), Blattfrucht (gehackt), Ackerfutteranbau (ohne Leguminosen), Ackerfutteranbau (mit Leguminosen),
- Abfuhr des Vorfrucht-Strohs; mit den Optionen ja/ nein,

- Zwischenfrucht; eingeteilt in die Kategorien keine Zwischenfrucht, Nichtleguminose (abfrierend), Nichtleguminose (winterhart), Leguminose (abfrierend), Leguminose (winterhart),
- Herbst-Düngung der Zwischenfrucht; mit den Optionen ja/ nein,
- und Abfuhr der Zwischenfrucht; mit den Optionen ja/ nein.

Alle getesteten Standort-Parameter sind quantitative Faktoren, zum einen Bodenparameter:

- der prozentuale Sand- und Tonanteil des Bodens in den oberen 0-30 cm Boden,
- der prozentuale Humusanteil in den oberen 0-20 cm Boden und
- $N_{minAussaats}$  [kg N/ha],

zum anderen Witterungsparameter, nämlich Niederschlagssumme [mm] und Temperaturmittelwert [dC]. Diese wurden auf der Basis langjähriger Witterungsdaten (30-jähriger Durchschnitt) für verschiedene Phasen der Saison des jeweiligen Standorts und Jahres berechnet:

- Winter (1. November – 31. Januar),
- Frühling (1. Februar – 31. März),
- Aussaat (April),
- frühes vegetatives (veg.) Wachstum (Mai),
- Hauptphase vegetatives Wachstum (1. Juni – 31. August),
- Nach der Blüte (1. September – 31. Oktober).

Für das Nettomineralisationsmodell wurde die N-Düngung als zusätzliche quantitative Managementgröße getestet. In Anlehnung an die DüV wurde zudem für beide Regressionsmodelle das Frischmasse-Ertragsniveau als zusätzlicher Standortparameter untersucht.

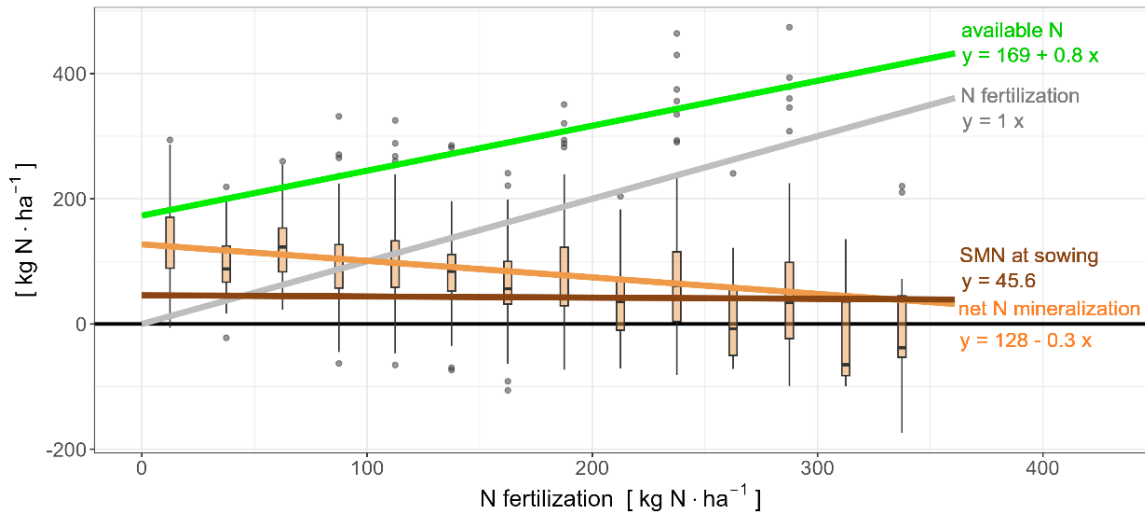
Von der Betrachtung ausgeschlossen wurden Versuchsdaten, bei denen eine Berechnung stattgefunden hat. Zudem mussten Informationen zu sämtlichen qualitativen und quantitativen Parametern vorliegen. Insgesamt umfasste der Datensatz zur Entwicklung des Nopt-Regressionmodells 224 Werte (120 Jahr/ Standort-Kombinationen) und der zur Entwicklung des Nettomineralisation-Regressionmodells 1182 Werte (111 Jahr/ Standort-Kombinationen).

Die Datenbank umfasst Nettomineralisationswerte zwischen -173.9 kg N/ha und 473.9 kg N/ha, im Mittel wurden 92.7 kg N/ha über die Silomaisaison freigesetzt. Das Nettomineralisations-Regressionmodell (Formel 10) beschreibt diese Variation mit einem  $R_{adj}^2 = 0.38$ . Das Modell umfasst neben der N-Düngung vier Managementparameter, 7 Witterungsparameter und einen Bodenparameter:

$$\begin{aligned}
 \text{Nettomineralisation [kg N/ha]} \approx & 35.0 - 0.3 \times N\text{-Düngung} - 1.2 \times \text{Niederschlag}_{\text{Frühjahr}} - 0.8 \times \\
 & \text{Niederschlag}_{\text{frühes veg. Wachstum}} - 1.7 \times \text{Niederschlag}_{\text{Hauptphase veg. Wachstum}} + \\
 & 3.6 \times \text{Niederschlag}_{\text{nach Blüte}} - 56.3 \times \text{Temperatur}_{\text{Frühjahr}} + 96.3 \times \\
 & \text{Temperatur}_{\text{Aussaats}} - 48.3 \times \text{Temperatur}_{\text{nach Blüte}} + 0.8 \times \text{Ton} + \\
 & \text{Pseudofaktor-Wert} \left( \begin{array}{l} \text{Vorfrucht, Abfuhr Vorfrucht-Stroh, Zwischenfrucht,} \\ \text{Abfuhr Zwischenfrucht} \end{array} \right) \quad (10)
 \end{aligned}$$

Hierbei hat der Pseudofaktor mit 53 % den größten Anteil an der Erklärungsgüte des Modells, 24 % sind auf die N-Düngung zurückzuführen, 6 % auf den Niederschlag in der Hauptphase des vegetativen Wachstums, 5 % auf die Temperatur zur Aussaat und 4 % auf die Niederschläge nach der Blüte. Als für die Nettomineralisation negativ werden eine erhöhte N-Düngung, stärkere Niederschläge während der Hauptphase des vegetativen Wachstums und nach der Blüte angerechnet, höhere Temperaturen zur Aussaat hingegen positiv. Auf die weiteren Modellkomponenten entfallen jeweils lediglich 1-2 %.

Der starke und negative Effekt der N-Düngung auf die Nettomineralisation (Abbildung 27) ist ein wichtiges Ergebnis vor dem Hintergrund der Steigerung der N-Effizienz im Maisanbau und passt zu den Ergebnissen von Carpenter-Boggs et al. (2000) und Mahal et al. (2019). Im Kontrast hierzu fanden beispielsweise Bonde und Rosswall (1987) und Zhang et al. (2012) eine erhöhte Mineralisierung durch N-Düngung. Diese Unterschiede könnten auf die Länge des betrachteten Messzeitraums zurückzuführen sein. Monaco et al. (2010) zeigten, dass die Nettomineralisation stark über die Saison hinweg fluktuiert, mit N-Immobilisierung früh in der Saison und starker N-Mineralisation kurz vor der Blüte. Daher könnte der von Bonde und Rosswall (1987) gewählte Messzeitraum von 13 Wochen zu kurz gewesen sein um die gesamte Dynamik über die Silomaisaison hinweg zu erfassen.



**Abbildung 27: Korrelation zwischen N-Düngung (grau) und potentiell pflanzen-verfügbarem N (grün), berechnet als Summe von N-Düngung, Nmin zur Aussaat (braun) und Nettomineralisation (orange). Die linearen Regressionen und ihre Funktionsgleichungen basieren auf dem gesamten Datensatz für N-Nettomineralisation. Die Boxplots zeigen die berechnete Nettomineralisation gruppiert in N-Düngeschritten von 25 kg N·ha<sup>-1</sup>, wobei Ausreißer als Punkte dargestellt werden.**

Die vier signifikanten Managementparameter Vorfrucht, Abfuhr des Vorfrucht-Strohs, Zwischenfrucht, Abfuhr der Zwischenfrucht beeinflussen in Abhängigkeit voneinander die Nettomineralisation. In Tabelle 12 sind alle Pseudofaktor-spezifischen Auf- bzw. Abschläge zur Berechnung der N-Nettomineralisation aufgelistet. So reduzierte zum Beispiel die Abfuhr des Vorfrucht-Getreide-Strohs in Kombination mit einer Winterbrache die Nettomineralisation. Dies kann auf eine erhöhte N-Auswaschung durch die fehlende Bodenbedeckung im Winter zurückgeführt werden. Wurde hingegen eine Nichtleguminose als Zwischenfrucht über den Winter angebaut, erhöht die Abfuhr des Vorfrucht-Getreide-Strohs die Nettomineralisation. Es wurde kein signifikanter Effekt der Herbst-Düngung auf die Nettomineralisation gefunden. Signifikante Unterschiede zwischen den Management-Varianten, sowie eine weitere Diskussion der identifizierten Standort- und Managementeffekte auf die Nettomineralisation wird im Rahmen einer Veröffentlichungen publiziert werden (Bukowiecki et al. Xa).

**Tabelle 12: Pseudofaktor (PF)-spezifische Auf- bzw. Abschläge [kg N·ha<sup>-1</sup>] zur Berechnung der N-Nettomineralisation in Formel 10 (ZF: Zwischenfrucht, NL: Nicht-Leguminose, L: Leguminose, a: abfrierend, w: winterhart).**

ZF- Abfuhr	ZF	Stroh- Abfuhr	Vorfrucht							
			Blattfrucht (gehackt)	Sommer -brache	Blattfrucht (gedroschen)	Getreide (gedroschen)	Grün- land (ohne L)	Getreide (Ganz- pflanzen- ernte)	Grün- land (mit L)	
keine	nein	nein	0.00	20.86	-60.33	-38.15				
		ja				-54.57	-93.12	-67.55		
	non-L (w)	nein			-40.92	-180.88				
		ja				-55.08		-26.87		
	nein	non-L (a)	nein			-46.19	-29.68			
		ja				64.73				
L (a)	nein				-7.48					
	ja						-171.29			
L (w)	nein							-19.26		
ja	non-L (w)	nein				-20.40				
		ja						-46.36		
	L (w)	nein			9.00					
		ja							-61.66	

Im Mittel des Datensatzes lag das Nopt bei 118.4 kg N/ha, und variierte in einem Bereich von 16.6-247.6 kg N/ha. Das in Formel 11 dargestellte Regressionsmodell beschreibt Nopt mit einem R<sub>adj</sub><sup>2</sup> = 0.3.

$$\text{Nopt} [\text{kg N/ha}] \approx 63.59 - 0.4 \times \text{Nmin zur Aussaat} + 4.1 \times \text{Humus} + 0.3 \times \text{Niederschlag}_{\text{Hauptphase veg. Wachstum}} - 10.5 \times \text{Temperatur}_{\text{Frühjahr}} + \text{Pseudofaktor-Wert}(\text{Vorfrucht, Abfuhr Vorfrucht-Stroh, Zwischenfrucht}) \quad (11)$$

Mit 51 % trägt der Pseudofaktor mehr als die Hälfte zur Erklärungsgüte des Modells bei, Humus 16 %, Nmin<sub>Aussaat</sub> 15 %, der Niederschlag während der Hauptphase des vegetativen Wachstums 15 %, und die Temperatur im Frühjahr 4 %. Damit sind der Niederschlag während der Hauptphase des vegetativen Wachstums und die Temperatur im Frühjahr in beiden Regressionsmodellen wesentliche Steuerungsgrößen.

Es konnte kein signifikanter Effekt der Herbst-Düngung und der Abfuhr der Zwischenfrucht festgestellt werden. Wie auch beim Nettomineralisations-Modell zeigte sich eine Interaktion der Managementeffekte. In Tabelle 13 sind alle Pseudofaktor-spezifischen Auf- bzw. Abschläge zur Berechnung der N-Nettomineralisation aufgelistet (Tabelle 13). Beispielsweise erhöhte die Abfuhr des Vorfrucht-Getreide-Strohs in Kombination mit einer Winterbrache das Nopt. Bei Anbau einer Nichtleguminose als Zwischenfrucht über den Winter, reduziert hingegen die Abfuhr des Vorfrucht-Getreide-Strohs das Nopt. Dies passt zu den Ergebnissen des Nettomineralisationsmodells, dementsprechend sinkt das Nopt, wenn die Nettomineralisation durch die Managementoptionen angeregt wird. Es wurde kein signifikanter Effekt der Herbst-Düngung und der Zwischenfrucht-Abfuhr auf das Nopt gefunden.

Es wurde ein signifikanter, Nopt reduzierender Effekt von Nmin<sub>Aussaat</sub> identifiziert. Im Vergleich zur DüV wurde jedoch nur eine 40 %-ige Wichtung vorgesehen, während die DüV vom optimalen N-Angebot den Nmin<sub>Aussaat</sub> zu 100 % abzieht. Dementsprechend werden laut Regressionsmodell 60 % nicht von der Pflanze genutzt. Ratjen und Kage (2018) fanden in Winterweizen Hinweise darauf, dass 26.8 % des im Frühjahr ermittelten mineralischen Bodenstickstoffs nicht pflanzenverfügbar sind. Sie brachten das mit der Textur in Verbindung; da höhere Frühjahrs-Nmin-Werte häufig auf tonigeren Böden auftreten, wo potentiell ein höherer Anteil des Bodenwassers und des darin gebundenen Stickstoffs nicht pflanzenverfügbar sind. Tatsächlich beschreibt das Nettomineralisations-Modell eine höhere Stickstofffreisetzung über die Silomaisaison auf Standorten mit toniger Textur. Eine andere Erklärungsmöglichkeit für ein nicht voll anzurechnendes Nmin sind Verluste vor der N-Aufnahme. Diese können im Fall des von Ratjen und Kage (2018) untersuchten Winterweizen als gering eingeschätzt werden, da bei der Frühjahrs-Nmin-Beprobung der Winterweizen bereits auf der Fläche etabliert ist, also die Stickstoff-Aufnahme aus dem Boden bereits läuft und der Bestand den Boden vor N-Verlusten durch Auswaschung schützen kann. Das Risiko gasförmiger N-Verluste ist im Frühjahr auf Grund niedriger Temperaturen eher gering. Im Vergleich dazu wird Nmin<sub>Aussaat</sub> im Silomais noch vor der Aussaat erhoben, bei deutlich höheren Temperaturen. So maßen Komainda et al. (2018) erhebliche N-Verluste in Form von Gasemission in der frühen Silomaisaison (nach Bodenbearbeitung und Aussaat). Da der Boden in diesem Zeitraum noch nicht durch den Bestand bedeckt ist, ist auch das Risiko für N-Auswaschung als höher einzustufen. Signifikante Unterschiede zwischen den Management-Varianten, sowie eine weitere Diskussion der identifizierten Standort- und Managementeffekte auf das N-Düngeoptimum werden im Rahmen einer Veröffentlichungen publiziert werden (Bukowiecki et al. Xb).

**Tabelle 13: Pseudofaktor (PF)-spezifische Auf- bzw. Abschläge [kg N-ha<sup>-1</sup>] zur Berechnung des Nopt in Formel 11 (ZF: Zwischenfrucht, NL: Nicht-Leguminose, L: Leguminose, a: abfrierend, w: winterhart).**

ZF	Stroh- Abfuhr	Vorfrucht					
		Blattfrucht (gehackt)	Sommerbrache	Blattfrucht (gedroschen)	Getreide (gedroschen)	Grünland (ohne L)	Getreide (Ganzpflanzenernte)
keine	nein	0.00	3.07	47.48	25.60		
	ja				50.86	36.68	54.86
non- L (w)	nein			4.21	115.61	14.08	
	ja				38.66		29.70
non- L (a)	nein			29.49	27.74		
	ja				17.52		
L (a)	nein			-12.00			
	ja				24.32		

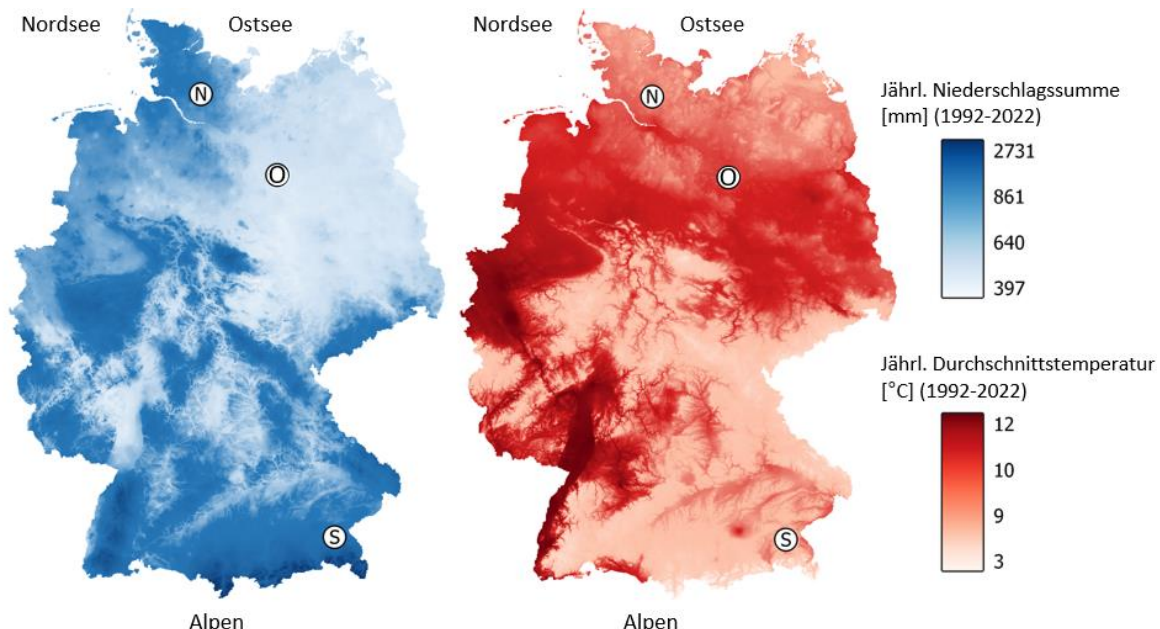
### Arbeitspaket 3, Teil 5: Anwendungsbeispiele

Beide Regressionsmodelle umfassen sowohl Managementparameter, als auch Witterungs- und Bodenparameter. Diese können theoretisch beliebig kombiniert werden, real liegen sie aber nur in einem begrenzten Umfang an Kombinationen vor. So werden zum Beispiel an sandigen Standorten mit hohen

Niederschlägen meist Winterzwischenfrüchte vor dem Mais etabliert, um das Risiko für N-Auswaschung zu verringern. Um daher die tatsächliche Variation der von den Modellen prognostizierten Nettomineralisation und des Nopt zu demonstrieren, wurden drei Silomais-Anbauszenarien formuliert und aus der Datenbank hierfür repräsentative Standorte ausgewählt (Tabelle 14, Abbildung 28):

- **Fallbeispiel Nord:** Im maritimen Norden Deutschlands sind die häufigsten Feldfrüchte Winterweizen und Wintergerste. Der Viehbesatz ist relativ hoch. Dementsprechend wurde als typische Vorfrucht für Silomais gedroschenes Getreide mit Strohabfuhr (Nutzung in der Viehhaltung) gewählt. Da die Standorte häufig sehr sandige Böden haben und der Winterniederschlag hoch ist, wird zur Verringerung des N-Auswaschungsrisiko zwischen den Hauptfrüchten meist eine schnellwüchsige, hohe Mengen an N aufnehmende Zwischenfrucht angebaut; eine winterharte Nichtleguminose.
- **Fallbeispiel Ost:** Im trockenen Osten Deutschlands erschweren sehr geringere Niederschläge und sandige Böden der Anbau von Winterungen und Zwischenfrüchten, und begünstigen demgegenüber den Anbau von Silomais-Monokulturen.
- **Fallbeispiel Süd:** Im präalpinen Süden Deutschlands sind die Böden tonig und die Witterungsverhältnisse kühl. Häufig wird Ackerfutter (ohne Leguminosen) angebaut, um das Vieh im Winter zu versorgen. Die Bedingungen nach der Ernte reichen nicht mehr für die Etablierung einer Winterzwischenfrucht aus.

Von den in der Datenbank vorliegenden Daten der drei ausgewählten Standorte wurde ein Mittelwert der Bodenparameter über alle Jahre berechnet (Tabelle 14). Humus und  $N_{min_{Aussaat}}$  unterscheiden sich kaum zwischen den Standorten (Tabelle 14). Die für das Nettomineralisationsmodell notwendige Eingangsgröße N-Düngung wurde nach DüV angesetzt (Bsp. Nord: 162 kg N/ha, Bsp. Ost: 175 kg N/ha, Bsp. Süd: 184 kg N/ha). Witterungsparameter wurden für eine Prognose der Nettomineralisation und des Nopt im Anbaujahr 2024 aus DWD-Daten berechnet (30-jährige Mittelwerte, Zeitraum: 1992-2022) (Abbildung 28).



**Abbildung 28:** Lage der als Fallbeispiel ausgewählten Standorte Nord (N), Ost (O) und Süd (S) in Deutschland. Links: jährliche Niederschlagssumme im Berechnungszeitraum, Rechts: jährliche Durchschnittstemperatur im Berechnungszeitraum. Kartengrundlage: [https://opendata.dwd.de/climate\\_environment/CDC/grids\\_germany/](https://opendata.dwd.de/climate_environment/CDC/grids_germany/).

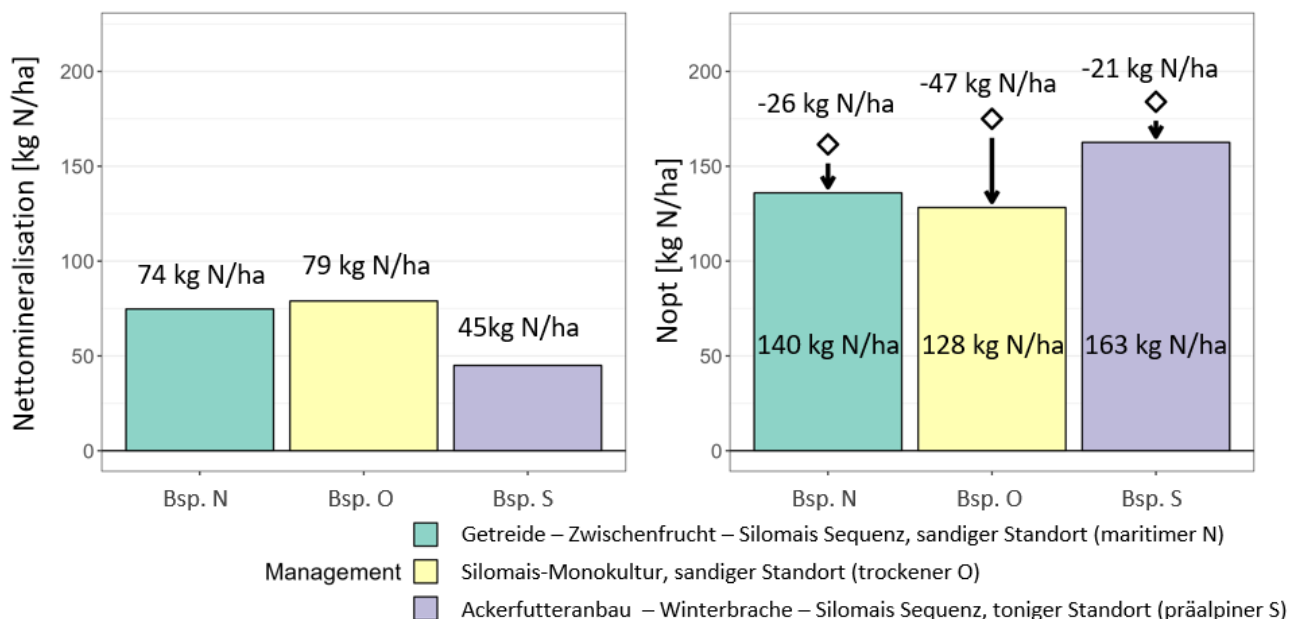
**Tabelle 14: Boden- und Managementparameter der als Fallbeispiel ausgewählten Standorte.**

Fallbeispiel	Humus [%]	Ton [%]	Sand [%]	$N_{min_{Aussaat}}$ [kg N/ha]	Management
Nord	3	2.5	92.5	28.0	Getreide (gedroschen), Strohabfuhr, Nichtleguminose (winterhart)
Ost	1.5	6.5	76	25.0	Silomais-Monokultur
Süd	1.5	20.7	9.7	28.5	Ackerfutteranbau (ohne Leguminosen), abgefahren, Winterbrache

Die für die drei Fallbeispiele prognostizierte Nettomineralisation unterscheidet sich erheblich (Abbildung 29). Im maritimen Norden wird mit 74 kg N/ha über die Silomaissaison geringfügig weniger N aus dem Boden freigesetzt als im trockenen Osten mit 79 kg N/ha. Im Kontrast zu diesen beiden Standorten, wird im präalpinen

Süden mit 45 kg N/ha von einer deutlich reduzierten Nettomineralisation ausgegangen. Das berechnete Nopt ist mit 163 kg N/ha im maritimen Süden am höchsten und im trockenen Osten mit 128 kg N/ha am niedrigsten (Abbildung 29). Das heißt, das Nopt ist an dem Standort mit der höchsten Nettomineralisation am niedrigsten und an dem Standort mit der niedrigsten Nettomineralisation am höchsten. Es findet jedoch keine 1:1-Anrechnung der erhöhten Nettomineralisation in Form eines reduzierten Nopts statt. Da Humus und  $N_{min_{Aussaat}}$  sich zwischen den Fallbeispielen kaum unterscheiden (Tabelle 14), lassen sich die Nopt-Unterschiede auf Witterungs- und Managementunterschiede zurückzuführen (Formel 11).

Zusätzlich sind in Abbildung 29 die für die Anwendungsbeispiele berechneten Düngeempfehlung nach DüV (DüV 2017) eingezeichnet. Diese sind in jedem der drei Beispiele deutlich höher als das mit dem Regressionsmodell berechnete Nopt. Die größte Überschätzung des tatsächlichen Nopt durch die DüV liegt bei dem Anwendungsbeispiel vor, in dem die Nettomineralisation am höchsten eingeschätzt wurde. Das führt zu der Annahme, dass es noch Optimierungspotential in der aktuellen DüV durch die Abbildung dieses Prozesses bzw. Berücksichtigung hierfür relevanter Management- und Standortparameter gibt. Hierbei sollte keine pauschale Reduktion der N-Düngung im Silomaisanbau angestrebt werden, sondern eine gezielte Anpassung an die N-Nachlieferungsunterschiede. Im Mittel des gesamten Datensatzes waren die N-Düngeempfehlungen nach DüV um 26% ( $MAE = 47.7 \text{ kg N}\cdot\text{ha}^{-1}$ ) höher als die berechneten Nopt. Die Korrelation zwischen der Düngeempfehlungen und den Nopts war sehr niedrig ( $R^2 = 0.08$ ).



**Abbildung 29: Mit den Regressionsmodellen für die Fallbeispiele im Jahr 2023 prognostizierte Nopt und Nettomineralisation. In der Nopt-Darstellung sind zusätzlich die Düngung nach DüV als Raute und die Differenz der DüV-Empfehlung und dem berechneten Nopt angegeben.**

### Arbeitspaket 3, Teil 6: Weitere Betrachtungen auf Grundlage der zusammengestellten bundesweiten Silomais-Datenbank

Das primäre Ziel der europäischen Landwirtschaft und der Agrarpolitik ist die Ertragssicherung. Daher ist die Basis vieler Düngeverordnungen (z.B. der deutschen Düngeverordnung (DüV 2017)) eine Abschätzung des N-Bedarfs des Bestandes, um mit der N-Düngeempfehlung ein für die Realisierung des Ertragspotentials ausreichendes N-Angebot zu gewährleisten. In den letzten Jahrzehnten ist jedoch die gleichzeitige Minimierung der Umweltauswirkungen zuzunehmen in den Fokus gerückt. Ein wesentlicher Aspekt hierbei ist die Verringerung der Grundwasserbelastung durch N-Einträge (European Parliament und Council of European Union Council 1991). Im Zuge dessen wurden viele europäische Düngeverordnungen überarbeitet, etwa durch eine Verringerung des für notwendig erachteten N-Angebots, einer Veränderung der Parameter zur Berechnung des N-Angebots oder eine Veränderung ihrer Anrechnung (DüV 2017; FR-FF 2013). In den vorherigen Kapiteln (Bukowiecki et al. Xb) wurden einige dieser Annahmen zur Abschätzung des N-Bedarfs für Silomais evaluiert und Möglichkeiten der genaueren Prognose des ökonomischen N-Düngeoptimums zum Zeitpunkt der N-Düngung identifiziert. Es ließe sich jedoch diskutieren, ob neben einer Betrachtung des Ertrags zukünftig auch Grundwasserschutz-fokussierte Aspekte zur Formulierung einer N-Düngeempfehlung genutzt werden sollten.

Bislang ungeklärt ist jedoch, wie stark der Effekt einer N-Auswaschungs-fokussierten Berechnung der N-Düngung auf den Ertrag wäre. Kühling et al. (2021) fanden ein großes Potential, die N-Düngung und damit die N-Auswaschungsverluste zu reduzieren ohne große Ertragseinbußen hinnehmen zu müssen. Im Kontrast dazu berichtet Goulding (2000) von nur geringfügig reduzierter N-Auswaschung bei gleichzeitig deutlich reduzierten Erträgen bei einer N-Düngung unter dem ökonomischen Optimum für Winterweizen. Die französische Düngeverordnung (FR-FF 2013) geht davon aus, dass solange die für den Ertrag optimale N-

Düngemenge nicht überschritten wird, das Nachernte-Nmin von der N-Düngung nicht beeinflusst wird, lediglich der Basiswert variiert in diesem Fall in Abhängigkeit der Kultur, der Durchwurzelungstiefe und des Bodentyps. Neben unterschiedlichen Kulturen und Bodenbedingungen könnten auch unterschiedliche Witterungsverhältnisse Ursache für diese unterschiedlichen Ergebnisse sein (z.B. erhöhte Auswaschung bei höheren Niederschlägen).

Auf Basis einer umfangreichen Datenbank deutscher Silomais-Feldversuche (Bukowiecki et al. Xa) wurde daher untersucht (1) wie stark sich das Nmin von Aussaat bis Ernte bei einer ökonomisch optimalen N-Düngung erhöht, (2) wie hoch die Ertragseinbußen bei einer N-Düngung zur Reduzierung der Nmin-Erhöhung von Aussaat bis Ernte ist und (3) inwieweit dieser Werte von Boden und Wetter beeinflusst werden.

### Datengrundlage und statistische Auswertung

Insgesamt konnten 105 Steigerungsreihen bestehend aus 625 Werten (jeweils mind. 4 N-Stufen pro Steigerungsreihe) ausgewertet werden. Diese stammen von 21 verschiedenen deutschen Standorten aus Versuchsjahren zwischen 1989-2022 (63 versch. Jahr x Standortkombinationen). Die Daten umfassen nur Standorte ohne Beregnung und mit rein mineralischer Düngung. Lagen Werte auf Parzellenebene vor, wurden sie zu Wiederholungsmitteln zusammengefasst. Die gesamte Datenverarbeitung und die statistische Auswertung erfolgten in R, version 4.1.0 (R Core Team 2022), unter Nutzung der Pakete „nlme“ (Pinheiro und Bates 2025) und „multcomp“ (Hothorn et al. 2016). Effekte wurden bei  $p < 0.05$  als signifikant erachtet.

Jahresdurchschnittstemperatur und Niederschlagssumme aus dem jeweiligen Versuchsjahr wurden über die Daten der am nächsten gelegenen DWD-Wetterstationen ([opendata.dwd.de](https://opendata.dwd.de)) entsprechende der Methodik von Bukowiecki und Rose, T., Kage, H. (2024) berechnet. Die Jahresdurchschnittstemperaturen variieren zwischen Standorten und Jahren zwischen 8.6-11.8 °C, die Niederschlagssummen zwischen 96.7-352.7 mm. Die untersuchten Bodenparameter (SOC in 0-20 cm [%], Sand in 0-30 cm [%], vorherrschende Bodenartuntergruppe in 0-120 cm) wurden von der BÜK200 (<https://geoportal.bgr.de/mapapps>) bezogen. In den Fällen in denen SOC oder Bodentyp auf der Versuchsfläche ermittelt wurden, wurden alternative diese Daten verwendet. Die Bodenarten wurden entsprechend der Ad-hoc-AG Boden (2005) in Bodenartengruppen zusammengefasst. Der Datensatz umfasst 56 Steigerungsreihen die der Bodenartengruppe Reinsand zuzuordnen sind, 29 x Lehmsande, 9 x Lehmschluffe, 7 x Schlufftone und 4 x Tonschluffe. Zu jeder Bodenartengruppe gehören mindestens zwei Standorte. Wenn die genaue Versuchslage nicht mehr bekannt war, wurde sie von den vorhandenen Informationen so genau wie möglich hergeleitet (z.B. Adresse der Versuchsstation).

Die Trockenmasse-Erträge wurden um einen Zuchtfortschritt von  $0.13 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{yr}^{-1}$  bereinigt, wobei das Zulassungsjahr bei unbekannter Sorte über das Jahr des Versuches hergeleitet wurde (Bukowiecki et al. Xb). Nmin-Werte über  $750 \text{ kg N}\cdot\text{ha}^{-1}$  wurden als unrealistisch aus dem Datensatz ausgeschlossen. Da Silomais nicht am Markt gehandelt wird, wurde über den Maispreisrechner der Landwirtschaftskammer Niedersachsen der Gleichgewichtspreis in Bezug auf Weizen als  $103.7 \text{ €}\cdot\text{t Frischmasse}^{-1}$  begerechnet ([https://www.lwk-niedersachsen.de/lwk/news/42056\\_Maispreis-Rechner](https://www.lwk-niedersachsen.de/lwk/news/42056_Maispreis-Rechner)). Hierbei wurden ein Weizenpreis von  $232.75 \text{ €}\cdot\text{t}^{-1}$  (<https://www.finanzen.net/rohstoffe/weizenpreis>) und ein N-Preis von  $1.16 \text{ kg N}\cdot\text{ha}^{-1}$  (Harnstoff, <https://www.lksh.de/landwirtschaft/markt/duengemittelpreise>), beides Stand 31.01.2025, angesetzt. Ein über die N-Stufen gleichbleibender TS-Gehalt von 35 % wurde zudem angenommen (Bukowiecki et al. Xb). Als ökonomisch realisierbarer Gewinn wurde der mit dem Silomais realisierte Erlös abzüglich der Kosten für den N-Dünger berechnet. Kosten für Überfahrten oder andere pflanzenbauliche Maßnahmen (z.B. Pflanzenschutz) wurden nicht berücksichtigt.

Für jede Steigerungsreihe wurde eine quadratische Funktion zwischen N-Angebot zur Aussaat (Summe von Nmin zur Aussaat und N-Düngung) und N-kostenfreier Leistung (NKFL) gefittet (Formel 12):

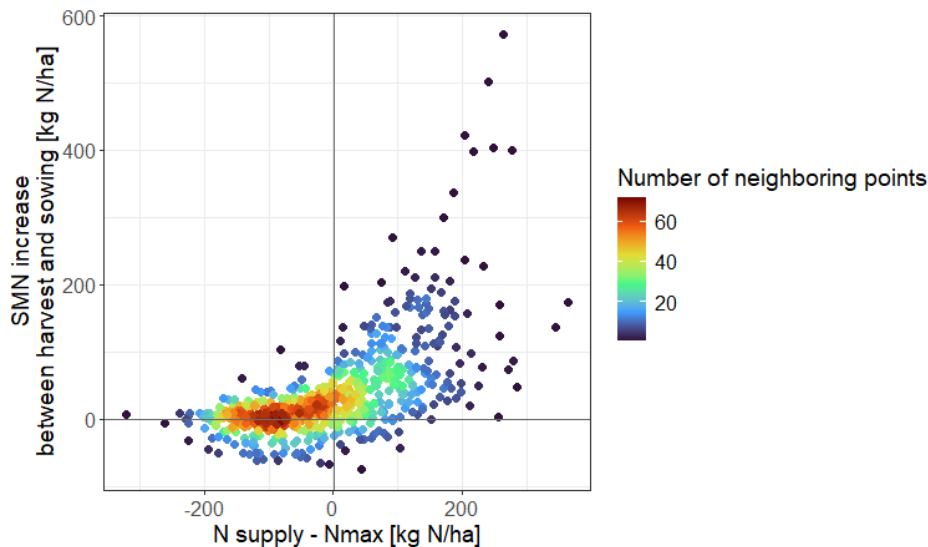
$$NKFL = a + b \times (Nmin_{Aussaat} + N - Düngung) + c \times (Nmin_{Aussaat} + N - Düngung)^2 \quad (12)$$

Zwar haben Bukowiecki et al. (Xb) gezeigt, dass der Zusammenhang von Ertrag zu N-Angebot eher einer quadratisch-plateau Funktion entspricht, bei einer Betrachtung des N-kostenfreien Erlöses kann jedoch durch steigende N-Kosten bei gleichbleibendem Ertrag mit einer Wiederabnahme, daher eher quadratischem Zusammenhang ausgegangen werden. Funktionen mit einem linearen Anstieg (b) über oder einem quadratischen (c) Anstieg unter Null wurden aus der Betrachtung ausgeschlossen. Mit den berechneten Parametern wurde für jede Steigerungsreihe der maximal erreichbare Erlös (NKFLmax) und das hierzu erforderliche N-Angebot (Nmax) berechnet.

Im nächsten Schritt wurde für jede Steigerungsreihe eine quadratische Funktion zwischen der Nmin-Differenz zwischen Ernte und Aussaat und der Differenz der N-Düngung zu Nmax gefittet (Formel 13):

$$(Nmin_{Ernte} + Nmin_{Aussaat}) = d + e \times (N - Düngung - Nmax) + f \times (N - Düngung - Nmax)^2 \quad (13)$$

Im Vorfeld wurde am gesamten Datensatz (Abbildung 30) die Annahme einer quadratischen Responsefunktion im Vergleich zur einer plateau-quadratischen oder einer plateau-linearen Funktion getestet, die ein unveränderliches  $N_{min}$  bis zum Überschreiten einer bestimmten  $N$ -Menge annehmen. Alle drei Funktionen erzielten den gleichen MAE ( $35.7 \text{ kg N}\cdot\text{ha}^{-1}$ ), die plateau-lineare Funktion jedoch mit  $55.8 \text{ kg N}\cdot\text{ha}^{-1}$  ein um  $0.1 \text{ kg N}\cdot\text{ha}^{-1}$  höheren RMSE als die beiden Funktionen mit quadratischem Term. Auf Grund eines geringeren AIC (quadratisch: 6699.4, plateau-quadratisch: 6699.7, plateau-quadratisch: 6703.0) und der höheren Stabilität beim Fitten der einzelnen Steigerungsreihen wurde der rein quadratische Ansatz für die weitere Betrachtung ausgewählt. Steigerungsreihen mit einem linearen (e) oder quadratischen (f) Anstieg unter Null wurden von der Betrachtung ausgeschlossen.



**Abbildung 30: Zusammenhang zwischen der  $N_{min}$ -Differenz zwischen Ernte und Aussaat und der Differenz der N-Düngung zu  $N_{max}$  des gesamten Datensatzes.**

Mit den berechneten Parametern wurde für jede Steigerungsreihe die geringste Differenz zwischen N-Düngung und  $N_{max}$  berechnet, bei der die Erhöhung des  $N_{min}$  zwischen Aussaat und Ernte minimal ist. Mithilfe der zuvor bestimmten N-Ertragsresponsekurven konnte dann bestimmt werden wie groß die prozentuale Reduktion der NKFL bei einer den  $N_{min}$ -Anstieg minimierenden N-Düngung ist (RedNKFL). War eine N-Düngung über  $N_{max}$  möglich ohne eine  $N_{min}$ -Erhöhung gegenüber dem Ausgangsniveau, wurde eine N-Düngung von  $N_{max}$  angenommen (RedNKFL = 0 %). Dieser Wert wurde im Weiteren als ökonomische Beurteilung einer N-Düngung vor dem Hintergrund ökologischer Überlegungen herangezogen, und der  $N_{min}$ -Anstieg infolge einer N-Düngung bei  $N_{max}$  ( $\Delta N_{minN_{max}}$ ) als ökologische Beurteilung einer ökonomisch-fokussierten N-Düngung.

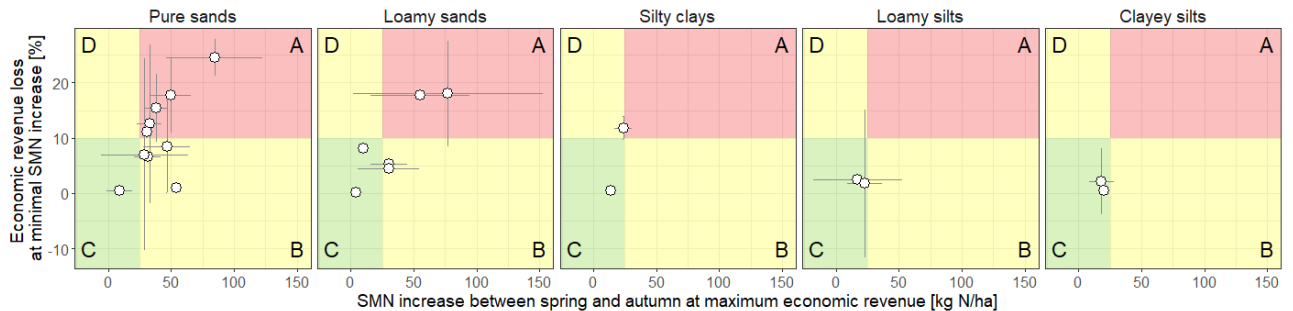
Der Einfluss von Bodenparametern und Witterung auf diese beiden Zielwerte wurde mittels einer ANOVA (Typ 1) untersucht. Hierfür wurde für jeden der Zielwerte ein gemischtes lineares Modell aufgestellt, das dessen Beeinflussung von den einzelnen Standortfaktoren, sowie den Interaktionen der quantitativen Bodenfaktoren mit den Witterungsparameter, untersucht (Sand x Jahresdurchschnittstemperatur, Sand x jährliche Niederschlagssumme, SOC x Jahresdurchschnittstemperatur, SOC x jährliche Niederschlagssumme). Der Standort wurde als Randomterm in das Modell aufgenommen, um Effekte nicht von diesen Parametern beschriebener Variabilität abzubilden (z.B. langjährige organische N-Düngung). Mit einem „weights“-Argument für jede Bodenartengruppe wurde der ansonsten sehr hohen Varianzheterogenität der Residuen entgegengewirkt. Von der ANOVA als nicht-signifikante Einflussgrößen identifizierte quantitative Einflussgrößen wurden vom Modell ausgeschlossen. Im Anschluss wurden die Effekte der Bodenartengruppe mittels eines einseitigen Grand Mean-Tests auf Signifikanzen analysiert.

## Ergebnisse

Im Mittel lag  $N_{max}$  bei  $176.9 \text{ kg N}\cdot\text{ha}^{-1}$ , mit einem Range von  $36.7\text{--}366.4 \text{ kg N}\cdot\text{ha}^{-1}$ . Die bei dieser N-Düngung erreichten maximalen NKFL variierten zwischen  $796.0\text{--}2857.7 \text{ €}\cdot\text{ha}^{-1}$ , mit einem Mittelwert von  $1840.3 \text{ €}\cdot\text{ha}^{-1}$ . Bei einer N-Düngung bei  $N_{max}$  war  $N_{min}$  nach Ernte im Mittel um  $35.5 \text{ kg N}\cdot\text{ha}^{-1}$  höher als zur Aussaat (Range =  $-20.9\text{--}249.9 \text{ kg N}\cdot\text{ha}^{-1}$ ).

Zur Minimierung der  $N_{min}$ -Erhöhung hätte im Mittel  $89.7 \text{ kg N}\cdot\text{ha}^{-1}$  unter  $N_{max}$  gedüngt werden müssen (vgl. Abb. 30), d.h. eine moderate N-Düngung verringert im Mittel  $N_{min}$ -Ernte. Die berechneten Werte waren jedoch sehr variabel, von einer N-Reduzierung um  $285.5 \text{ kg N}\cdot\text{ha}^{-1}$  bis zu einer möglichen Erhöhung der N-Düngung über  $N_{max}$  von  $138.5 \text{ kg N}\cdot\text{ha}^{-1}$  ohne einen  $N_{min}$ -Anstieg über das Ausgangsniveau. Die NKFL wären damit im Mittel um 8.5 % reduziert worden, die maximale RedNKFL beträgt 64.2 %.

Sowohl die Erlöseinbußen bei einer ökologisch fokussierten N-Düngung wie auch die N<sub>min</sub>-Erhöhung bei einer ökonomisch basierten N-Düngung variieren stark zwischen den Standorten (Abbildung 31). Hierbei ist ein deutlicher Einfluss der Bodentypen erkennbar. Bei einer fiktiven ökonomischen Grenze der RedNFKL von 10 % und einer ökologischen  $\Delta N_{minN_{max}}$ -Grenze von 25 kg N·ha<sup>-1</sup> ordnen sich sämtliche Standorte mit Lehmschluffen und Tonschluffen in einem in beiderlei Hinsicht für den Silomais-Anbau unkritischen Bereich ein. Auf den Schlufftonen ist der Silomais-Anbau mit diesen Indikatoren als ökologisch unbedenklich einzuordnen. Nur auf den sandigen Standorten, insbesondere auf den Reinsanden, liegen Standorte im Mittel der Versuchsjahre in einem ökologisch und z.T. zusätzlich auch ökonomisch kritisch einzuordnenden Bereich. Dies ist insofern besonders kritisch als sich der Silomaisanbau gerade auf diese typischen Veredelungsstandorte konzentriert.



**Abbildung 31: Pro Standort berechneter Mittelwert und Standardabweichung für die N<sub>min</sub>-Erhöhung bei einer Düngung von N<sub>max</sub> und der prozentualen Reduktion der N-kostenfreien Leistung bei einer N-Düngung zur Reduktion der N<sub>min</sub>-Erhöhung. Die Fenster unterscheiden die Standorte nach Bodentyp. Farbig hinterlegt sind vier Quadranten, die sich aus einer ökonomisch maximal hinnehmbaren Reduktion der N-kostenfreien Leistung um 10 % und einer ökologisch maximal hinnehmbaren Erhöhung der N<sub>min</sub>-Werte zwischen Aussaat und Ernte von 25 kg N·ha<sup>-1</sup> ergeben (beides theoretische Schwellenwerte): (A) potentiell ökologisch und ökonomisch problematische Standort, (B) potentiell ökologisch kritisch, (C) Anbau von Silomais in beiderlei Hinsicht unkritisch, (D) potentiell ökonomisch kritisch.**

Die gleichen Standortparameter haben einen signifikanten Effekt auf die N<sub>min</sub>-Erhöhung bei N<sub>max</sub> und die RedNKFL (Tabelle 15); Sand- und SOC-Gehalt im Oberboden und die Interaktion von SOC und Jahresdurchschnittstemperatur. Außerdem wurden signifikante Unterschiede zwischen den Bodenartengruppen identifiziert. Die Jahresniederschlagssumme hatte weder einzeln, noch in Interaktion mit SOC oder Sand einen signifikanten Effekt.

Die Richtungen der Effekte auf  $\Delta N_{minN_{max}}$  und die NKFL sind invers; was zu einem niedrigeren  $\Delta N_{minN_{max}}$  führt, erhöht die NKFL bei einem minimalen N<sub>min</sub>-Anstieg bzw. reduziert dementsprechend die RedNFKL (Abbildung 32, Abbildung 33). Da die Effektstärke nicht nur an der Höhe der Modellkoeffizienten, sondern auch an dem Range der Parameterausprägung liegt, wurde deren Koeffizient in Abbildung 32 und Abbildung 33 dargestellt.

Dabei reduziert ein höherer Sandgehalt in 0-30 cm den  $\Delta N_{minN_{max}}$  um im Mittel 54.5 kg N·ha<sup>-1</sup> bzw. verringert die RedNKFL um 22.1 %. Das könnte auf eine höhere Auswaschung an sandigeren Standorten zurückzuführen sein. Hieraus folgt auch, dass die alleinige Betrachtung von N<sub>min</sub>-Nachernte nicht ausreicht, um das Risiko des N-Austrags in das Grundwasser abzuschätzen. Weiterhin gilt es zu beachten, dass die dargestellten Analysen sich auf die Änderung des N<sub>min</sub> von Frühjahr zu Herbst beziehen und der Ausgangswert der N<sub>min</sub>-Gehalte im Frühjahr ergänzend in die Betrachtung einbezogen werden müsste.

Der Effekt von SOC und der Interaktion zwischen SOC und Jahresdurchschnittstemperatur sind invers und neutralisieren sich zu großen Teilen und sollten daher gemeinsam betrachtet werden. Aufsummiert erhöhen die Terme den  $\Delta N_{minN_{max}}$  im Mittel um 9.1 kg N·ha<sup>-1</sup> und die RedNKFL um 3.2 %. Dieser Effekt könnte mit der höheren N-Nachlieferung an SOC-reicheren Standorten zusammenhängen, die das N<sub>min</sub> zwischen Aussaat und Nachernte zusätzlich erhöht.

Der stärkere Effekt des Sandgehalts dominiert den gemeinsamen Effekt aller quantitativer Standortparameter, der -45.4 kg N·ha<sup>-1</sup> auf den  $\Delta N_{minN_{max}}$  und -18.9 % auf die RedNFKL beträgt. Dabei ist auch die Variabilität des Sand-Effekts innerhalb des Datensatzes deutlich stärker als der des SOC samt Interaktion mit Bodentemperatur.

Demgegenüber stehen die Effekte der Bodenarten, die sowohl  $\Delta N_{minN_{max}}$  als auch RedNFKL erhöhen. Der Effekt der Bodenartengruppen auf die NFKL ist deutlich ausgeprägter als auf den  $\Delta N_{minN_{max}}$  (Tabelle 15). Dabei ist die NFKL bei Reinsanden signifikant niedriger, bzw. die RedNFKL signifikant höher. Dem Gegenüber ist  $\Delta N_{minN_{max}}$  bei Schlufftonen, Lehmschluffen und Tonschluffen signifikant niedriger als der Mittelwert aller Daten. Das stimmt mit der Interpretation von Abbildung 31 überein, dass auf schwereren Standorten sowohl der gewählte ökologische wie auch der ökonomische Indikator als weniger kritisch als auf den sandigeren Standorten ausfallen.

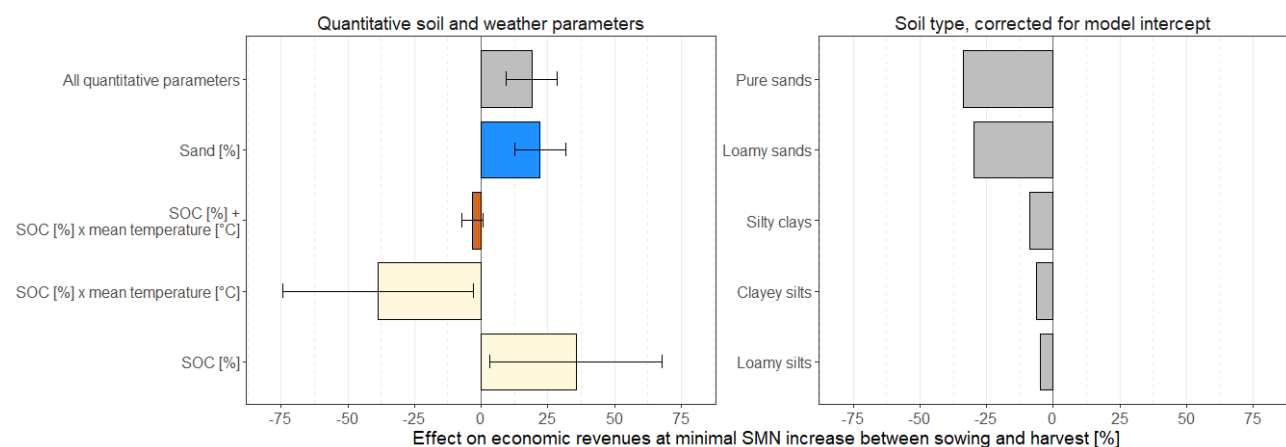
Im Vergleich der Effekte ist der positive Effekt der sandigeren Bodenarten (quantitativer Standortfaktor; bspw. Reinsande, Lehmsande) auf  $\Delta N_{minN_{max}}$  und RedNFKL deutlich stärker als der negative Effekt der quantitativen

Standortfaktoren. Da der Datensatz ein großes Spektrum an Anbaubedingungen innerhalb von Deutschland repräsentiert, kann also relativ unabhängig vom Effekt der Oberboden- und Witterungsparameter von einer Erhöhung des  $\Delta N_{minN_{max}}$  und der RedNFKL bei sandigen Bodentypen ausgegangen werden. An Standorten, an denen jedoch sowohl der Oberboden wie auch der Bodentyp insgesamt bis in 120 cm Tiefe sand-dominiert ist, kann diese Erhöhung durch den Effekt des Sandgehalts im Oberboden jedoch deutlich reduziert werden (vermutlich besonders hohes Auswaschungsrisiko über die Saison). Auf den schwereren Texturen (Tonschluffe, Lehmschluffe und insbesondere bei den Schlufftonen) überwiegen im Mittel die Effekte der quantitativen Parameter innerhalb des Modells, was zu einer Reduzierung des  $\Delta N_{minN_{max}}$  und der RedNFKL führt.

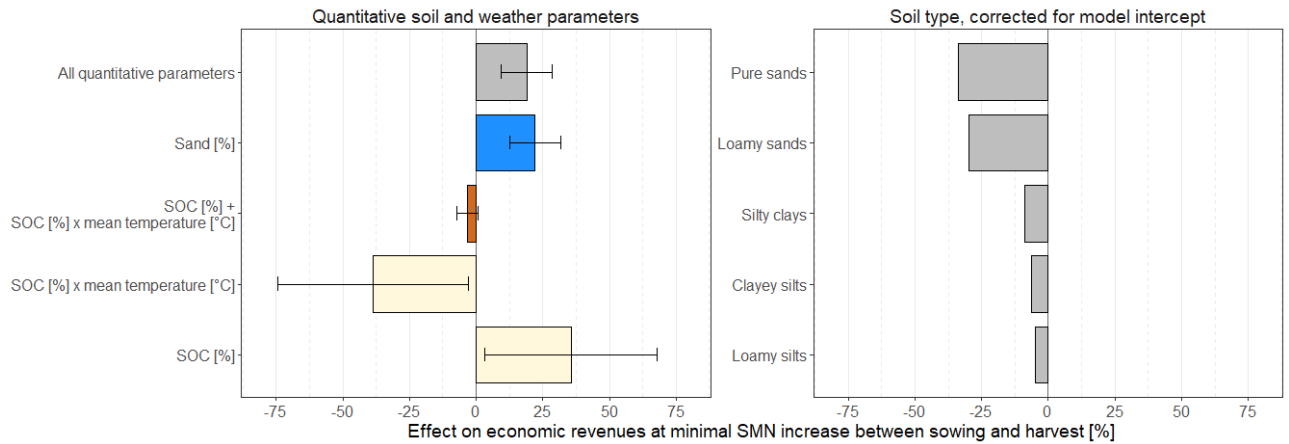
Im Sinne eines ökologisch und ökonomisch unkritischen Silomaisanbaus kann daher geschlussfolgert werden, dass Standorte optimal sind, in denen der Oberboden sandig ist, das Bodenprofil jedoch insgesamt einen hohen Schluff- oder Ton-Gehalt aufweist. Standorte mit durchgängig Sand-dominierten Bodenprofilen sind hingegen als kritisch einzustufen. Auf warmen Standorten und stark humosen Standorten muss entsprechend weniger gedüngt werden, was jedoch die Wirtschaftlichkeit nicht stark beeinträchtigt.

**Tabelle 15: Effekte der getesteten Boden- und Witterungsparameter (SOC = organischer Kohlenstoffgehalt im Boden). Die Signifikanzen der quantitativen Parameter sind Ergebnis der ANOVA, die Unterschiede zwischen den Bodentypen des Grand Mean Tests.**

Parameter	p-Werte	
	Effekt auf NKFL bei N-Düngung für minimalen Nmin-Anstieg	Effekt auf Nmin-Erhöhung bei N-Düngung = Nmax
Sand 0-30 cm [%]	<.0001	0.0005
SOC 0-20 [%]	0.0003	0.0031
SOC x Temperatur	0.0094	0.0418
Bodenartengruppe	0.0201	0.1436
Reinsande >= 0	0.0437	n.s.
Lehmsande >= 0	n.s.	n.s.
Schlufftone >= 0	n.s.	0.0404
Lehmschluffe >= 0	n.s.	0.0791
Tonschluffe >= 0	n.s.	0.0660



**Abbildung 32 Links: Effekt der als signifikant ermittelten quantitativen Standortparameter auf die ökonomischen Erlöse bei einer N-Düngung zur Minimierung des Nmin-Anstiegs zwischen Aussaat und Nachernte über den gesamten Datensatz betrachtet (Produkt von Parameterkoeffizient und Parameterausprägung), zusammengefasst in Mittelwert und Standardabweichung. Ein negativer Effekt auf die ökonomischen Erlöse entspricht einer Erhöhung der RedNFKL. Die Effekte von SOC (organischer Kohlenstoffgehalt des Bodens) und SOC in Interaktion mit der Jahresdurchschnittstemperatur sind sowohl einzeln, als auch aufsummiert dargestellt. „All quantitative parameters“ ist der aufsummierte Effekt aller signifikanter quantitativer Standortparameter. Rechts: Effekte der Bodenartengruppen.**



**Abbildung 33: Effekt der als signifikant ermittelten quantitativen Standortparameter auf den Nmin-Anstieg zwischen Aussaat und Nachernte bei einer N-Düngung von Nmax über den gesamten Datensatz betrachtet (Produkt von Parameterkoeffizient und Parameterausprägung), zusammengefasst in Mittelwert und Standardabweichung. Die Effekte von SOC (organischer Kohlenstoffgehalt des Bodens) und SOC in Interaktion mit der Jahresdurchschnittstemperatur sind sowohl einzeln, als auch aufsummiert dargestellt. Rechts: Effekte der Bodenartengruppen. „All quantitative parameters“ ist der aufsummierte Effekt aller signifikanter quantitativer Standortparameter. Rechts: Effekte der Bodenartengruppen.**

#### Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation

##### Hintergrund

Die Mineralisierung von Stickstoff (N) im Boden ist ein wesentlicher biogeochemischer Prozess in landwirtschaftlichen Systemen, der die Verfügbarkeit von N für die Pflanzenaufnahme und -wachstum reguliert. Dieser Prozess wird durch die Netto-N-Mineralisierung gesteuert, die das Gleichgewicht zwischen zwei mikrobiellen Prozessen ist: der Bruttomineralisierung, bei der organischer N in anorganische Formen wie Ammonium ( $\text{NH}_4^+$ ) und Nitrat ( $\text{NO}_3^-$ ) umgewandelt wird, und der Immobilisierung, bei der anorganischer N von Bodenmikroorganismen assimiliert wird (Bruun et al. 2006; Chen und Leffler 2024; Schimel und Bennett 2004). Trotz seiner Bedeutung im N-Kreislauf und der Effizienz von N-Düngemitteln wird die Rate der N-Mineralisierung im Boden (SNMR) in modernen Düngungsplanungssystemen aufgrund der Komplexität und des arbeitsintensiven Charakters des Bestimmungsprozesses nicht ausreichend genutzt. Gleichzeitig kann Mais aufgrund seiner im Vergleich zu Wintergetreide zeitlich späteren und länger ins Jahr reichenden vegetativen Entwicklung große N-Mengen aufnehmen, die im Verlauf der Vegetationsperiode durch SNMR freigesetzt werden.

Traditionelle Methoden wie Langzeitinkubation zur Abschätzung sind zwar genau, jedoch zeitaufwendig und invasiv (Agostini et al. 2024; Chen und Leffler 2024; Huang et al. 2024; LIU et al. 2024). Darüber hinaus wird die SNMR von einer Vielzahl von Faktoren beeinflusst, darunter die Fruchtfolge, Bodentemperatur, Bodenfeuchte und andere physikalische Eigenschaften, was eine präzise N-Düngeempfehlung unter Berücksichtigung der SNMR erschwert (Dessureault-Rompré et al. 2015). So gilt gemäß der Düngeverordnung in Deutschland, dass auf Böden mit mehr als 4 % organischer Substanz,  $20 \text{ kg N ha}^{-1}$  vom N-Bedarfswert abgezogen werden, während auf Böden unterhalb dieses Schwellenwerts keine Abzüge vorgenommen werden. Dies erscheint angesichts von Daten von Heumann et al. (2014), die eine Variation der SNMR von  $13\text{--}198 \text{ kg N ha}^{-1}$  für Mais belegt, fraglich. Da mehr als 80 % der Ackerböden in Deutschland weniger als 4 % organische Substanz aufweisen und unter Berücksichtigung der langen Vegetationsperiode für Mais, besteht großes Potenzial, den N aus SNMR zu nutzen (Benbi und Richter 2002). Zudem wurde in AP3 ein großes Potential zur Reduktion der N-Überschüsse durch eine Anpassung der Düngeverordnung an die tatsächlichen Nettomineralisationsvariationen im Silomaisanbau identifiziert (Bukowiecki et al. Xa, Xb). Angesichts der Komplexität der N-Dynamik und der Begrenzungen der bestehenden Analysemethoden besteht ein dringender Bedarf an verbesserten Techniken zur schnellen und zuverlässigen Schätzung des SNMR-Potentials. Dies ist entscheidend für eine effektive N-Düngeplanung, insbesondere angesichts der wachsenden Umweltbedenken hinsichtlich Nitratauswaschung und Treibhausgasemissionen (Cui et al. 2014; Degaspari et al. 2020; Guo et al. 2010; Snyder et al. 2009).

Die Nahinfrarotspektroskopie (NIRS) stellt ein anerkanntes Tool zur durchsatzstarken, kostengünstigen, nicht-destruktiven und umweltfreundlichen Analyse für Inhaltsstoffe organischer Materialien dar (Reijnveld et al. 2022; Sharma et al. 2024). Diese Technik ist weit verbreitet zur Schätzung der Nährstoffkonzentrationen im Boden in verschiedenen Ökosystemen (Du et al. 2025)(Du et al., 2025; Krzebietke et al., 2023 (Krzebietke et al. 2023; Zhong et al. 2024). Sie wird häufig verwendet, um die Gehalte von organischer Substanz, des Gesamt-Kohlenstoff, des Gesamt-Stickstoffs sowie von Boden-pH, Bodensalinität, Bodenstruktur u.ä. zu schätzen (Zhong et al. 2024; Bai et al. 2024; Jaconi et al. 2019; Santasup et al. 2024; Seifi et al. 2020). Da

NIRS Molekylvibrationen erkennt, die sowohl mit organischen als auch mit anorganischen Substanzen verbunden sind, eignet sich die Methode besonders gut, um die Komplexität der Bodenkomponenten zu erfassen. Im elektromagnetischen Spektrum arbeitet NIRS im Bereich von 700 bis 2500 nm im nahen Infrarotbereich. Sie ist empfindlich gegenüber den Über-tonen und Kombinationsbändern der fundamentalen Schwingungsfrequenzen, die mit wichtigen chemischen Bindungen wie C–H, N–H, O–H und C=O verbunden sind (Moreno-Rojas et al. 2015). Diese stehen in enger Beziehung zur SMNR.

Trotz der umfangreichen Anwendung von NIRS-basierten Vorhersagemodellen zur Schätzung von Nährstoffen und Eigenschaften im Boden, bleibt die spezifische Vorhersage der SMNR ein bisher unerschlossenes Forschungsgebiet. Frühere Forschungen haben hauptsächlich im sichtbaren nah-Infrarot (vis-NIR) Bereich des Spektrums gearbeitet, um die SMNR zu schätzen (Ruma et al. 2024a, 2024b). Soweit wir wissen, wurden bisher keine Studien durchgeführt, die NIRS speziell zur Vorhersage der SMNR in landwirtschaftlichen Böden angewendet haben. Um diese Lücke zu schließen, konzentriert sich diese Auswertung auf den Aufbau von Vorhersagemodellen für die SMNR im Boden, indem Spektral-daten aus NIRS über eine Vielzahl von Bodenproben aus ganz Deutschland genutzt werden. Eine Herausforderung bei der Entwicklung dieser Modelle ergibt sich aus der Komplexität der N-Formen im Boden, da N in verschiedenen organischen und anorganischen Zuständen vorkommen kann, was die spektralen Absorptionsmerkmale beeinflusst. Nichtsdestotrotz ist die Vorhersage der SMNR im Boden entscheidend für die Optimierung des N-Managements, das auf lokale Bedingungen abgestimmt ist, sodass präzise N-Düngemengen abgeleitet werden können.

Im NIR-Bereich sind Absorptionmessungen oft mit Analytenkonzentrationen verbunden, die in der Regel eine nichtlineare Beziehung aufweisen, was traditionelle univariate Kalibrierungsmethoden unbrauchbar macht. Um dieses Problem zu lösen, sind multivariate Kalibrierungsansätze erforderlich, die sowohl lineare als auch nichtlineare Beziehungen berücksichtigen können. Deshalb werden unterschiedliche konventionelle Methoden mit Machine Learning Ansätzen verglichen (Devianti et al. 2022): darunter Random Forest (RF), Support Vector Machine (SVM) mit Radial Basis Function (RBF)-Kernel, Extreme Gradient Boosting (XGBoost) und künstliche neuronale Netzwerke (ANN) sowie ein gestapeltes Modell aus SVM, XGBoost und ANN zur Verbesserung der Vorhersagegenauigkeit. Diese nichtlinearen Methoden haben sich als besonders effektiv erwiesen, um komplexe Muster in Absorptionsspektren zu erfassen, was eine robustere Schätzung des SMNR-Potentials im Boden ermöglicht (Fidêncio et al. 2002; Tang et al. 2024).

## Material und Methoden

Im Winter 2021/2022 und 2022/2023 wurden umfangreiche Bodenbeprobungen durchgeführt (Abbildung 34), um das Mineralisierungs- und/oder Immobilisierungspotenzial verschiedener Bodentypen in ganz Deutschland zu untersuchen. Dafür wurde in Inkubationsexperimenten mit ungestörten Bodenproben die SMNR quantitativ erfasst. Zeitgleich wurden die Bodenproben laboranalytisch auf unterschiedliche Parameter hin untersucht und jede Probe mittels NIRS gemessen.

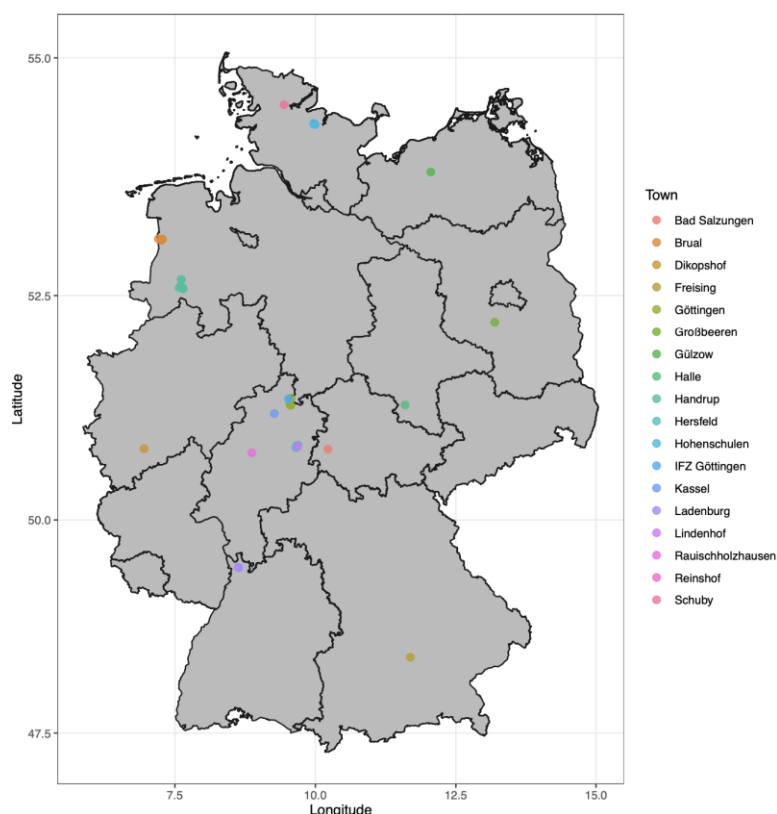


Abbildung 34. Standorte der Bodenprobenahmen

## Erstes Inkubationsexperiment (Winter 2021/2022)

Im ersten Versuch sammelten wir 219 ungestörte Bodenproben aus 42 Feldstandorten an 18 pedoklimatischen Standorten in Deutschland. Die Bodenproben (11 cm Innendurchmesser, 12 cm Tiefe) wurden ungestört aus dem Oberboden (10–25 cm Tiefe) mit einem mobilen Probenahmegerät (UGT, Müncheberg, Deutschland) entnommen. Die Probenahme wurde über einen Zeitraum von acht Wochen im Winter durchgeführt, um mikrobielle Aktivität innerhalb der Bodenproben zu vermeiden. Die gesammelten Bodenproben repräsentierten ein breites Spektrum an Gehalten an organischer Substanz, das sich aus Unterschieden in vorherigen Kulturen, Bodentypen, Erntemethoden sowie Düngungsarten und -mengen ergab.

Jede Probe wurde in Acrylröhren verpackt und mit Polyethylen-Verschlusskappen versiegelt. Um die Integrität der Proben zu wahren, wurden die Bodenproben in einem Kühlfahrzeug ins Labor transportiert. Diese ungestörten Bodenproben wurden anschließend für 100 Tage unter kontrollierten Laborbedingungen bei einer Temperatur von  $17.5 \pm 0.6^\circ\text{C}$  im Dunkeln aerob inkubiert. Während der Inkubationsperiode wurde der Bodenwassergehalt gravimetrisch überwacht und bei Bedarf angepasst, um gleichbleibende Feuchtigkeitsbedingungen sicherzustellen. Anfangs- und Endwassergehalt im Boden waren daher nahezu identisch, da der Trockengehalt des Bodens im Durchschnitt bei 82.2 % und 82.6 % lag.

## Zweites Inkubationsexperiment (Winter 2022/2023)

Im zweiten Versuch konzentrierten wir uns auf zwei Experimentierstandorte: Reinshof (Göttingen) und Hohenschulen (Kiel). An diesen Standorten sammelten wir jeweils 60 und 40 ungestörte Bodenproben unter Verwendung derselben Probenahmetechnik wie im ersten Versuch. Der Boden wurde aus dem Oberboden in einer Tiefe von 10–20 cm entnommen. Die Göttinger Proben wurden über fünf Zeitpunkte inkubiert: 5, 10, 25, 50 und 100 Tage, während die Hohenschulen-Proben über eine einzige Dauer von 100 Tagen inkubiert wurden. Die Proben wurden ebenfalls unter kontrollierten Laborbedingungen bei  $17.2 \pm 0.5^\circ\text{C}$  und unter dunklen und feuchten Bedingungen inkubiert. Ähnlich wie im ersten Versuch wurde der Bodenfeuchtigkeitsgehalt während der gesamten Inkubationsperiode gravimetrisch überwacht und angepasst, um konstante Feuchtigkeitsbedingungen sicherzustellen. Die Anfangs- und Endwassergehalte in diesem Versuch waren ebenfalls nahezu gleich, wobei der Trockengehalt des Bodens (TS) im Durchschnitt bei 82.5 % und 84.3 % lag. Abbildung 35 vermittelt einen Eindruck der Vorgehensweise.



**Abbildung 35 Beispielhafte Darstellung eines Probenahmestandortes mit Versuchspartzen, Entnahmegerät, verschlossener und ungestörter Bodenprobe sowie inkubierten Proben im Labor (von links nach rechts).**

Der Nmin-Gehalt des Bodens wurde vor der Inkubation (T<sub>0</sub>) und nach der Inkubation (T<sub>1</sub>) gemessen. Die Differenz zwischen T<sub>1</sub> und T<sub>0</sub> wurde berechnet, um die Nettostickstoffmineralisierung oder -immobilisierung während der Inkubationsperiode zu quantifizieren. Die SMNR bildet sich als Differenz zwischen Nmin zu Beginn der Inkubation und zum Ende der Inkubation nach 100 Tagen, geteilt durch die Anzahl Tage. Ein Zeitraum von 100 Tagen wurde gewählt, weil dies in etwa dem Zeitraum entspricht, in welchem Mais in Deutschland von Aussaat bis zur Blüte wächst und den Großteil der N-Menge akkumuliert. Für die weitere Analyse und Vorhersagemodellierung wurden die Daten aus beiden Inkubationsversuchen kombiniert.

## Gestörte Bodenproben für Laborreferenzmessungen

Alle Proben aus dem ersten und zweiten Inkubationsexperiment wurden mit denselben analytischen Verfahren untersucht, einschließlich der Messungen des Gesamtgehalts an Kohlenstoff (C) und Stickstoff (N), der pflanzenverfügbaren Nährstoffe (P, K, Mg), des Boden-pH-Werts und der Bodenstruktur (wo anwendbar). Zusätzlich wurden für jeden Standort mittels eines Fragebodens eine umfangreiche Liste an Metadaten zusammengestellt, die Fruchtfolgehistorie, die Düngungsmanagementdaten und meteorologische Daten umfassen. Zusätzlich wurde für jeden Standort und jedes Jahr das Management in den letzten drei Jahren vor der Beprobung abgefragt; inklusive der angebauten Kulturen, der verwendeten Düngertypen (organisch, mineralisch) und der applizierten Mengen an Stickstoff, Phosphor, Kalium und Schwefel. Das Management der Flächen für die Inkubationsreihen ist in Tabellen 16 und 17 gezeigt.

An jedem Probenahmestandort wurden gestörte Bodenproben aus mehreren Bodenkerndurchmessern (2 cm Durchmesser) in der gleichen Tiefe in der Nähe der ungestörten Bodenprobenahme entnommen, um die Ausgangseigenschaften des Bodens zu bestimmen. Insbesondere wurden gestörte Proben verwendet, um

den initialen Gehalt an mineralischem Stickstoff ( $N_{min} = \text{Nitrat-N} + \text{Ammonium-N}$ ) zum Zeitpunkt der Probenahme ( $T_0$ ) zu analysieren sowie die Bodenstruktur (Sand-, Ton- und Schluffgehalte), den Boden-pH ( $\text{CaCl}_2$ ) und die Gehalte an pflanzenverfügbaren Phosphor und Kalium (CAL-Methode) sowie Magnesium ( $\text{CaCl}_2$ ) zu bestimmen.

Der mineralische N ( $N_{min}$ ) im Boden ( $N_{min} = \text{NO}_3\text{-N} + \text{NH}_4\text{-N}$ ) wurden aus den Proben durch Zugabe von 0.01 mol  $\text{CaCl}_2$  und Schütteln für 1 h extrahiert. Die gefilterten Extrakte wurden dann mit einem Durchflussanalysator (Seal Analytical; Modell: QuAAtro39 AutoAnalyzer) auf  $\text{NH}_4\text{-N}$  und  $\text{NO}_3\text{-N}$  analysiert. Die  $N_{min}$ -Menge ( $\text{kg ha}^{-1}$ ) wurde unter Berücksichtigung des tatsächlichen Bodenwassergehalts (Trocknung bei 105 °C) und der Schüttdichte berechnet.

Eine weitere Unterprobe wurde bei 60°C weiter getrocknet, gemahlen und auf den Gesamtgehalt an Kohlenstoff (C) und Stickstoff (N) mittels Elementaranalyse (Vario el Cube, Elementar Analysensysteme GmbH, Langenseibold, Deutschland) nach Mahlung auf eine Partikelgröße von 0.2 mm analysiert. Für Proben, die Karbonat enthielten, wurde der Gehalt an organischem Kohlenstoff durch Verbrennung der Unterproben in einem Muffelofen bei 550°C für drei Stunden vor der Analyse isoliert. Der organische Kohlenstoffgehalt wurde dann mit einem Umrechnungsfaktor in den Gehalt an organischer Substanz umgerechnet, und das C/N-Verhältnis wurde basierend auf der organischen Fraktion bestimmt.

In einer weiteren Unterprobe wurden die Konzentrationen von P und K in einer kontinuierlichen Flussanalyse gekoppelt mit einem Flammenphotometer (Kalium) oder UV/VIS-Spektrophotometer (Phosphor) (San System, Skalar, Niederlande) bestimmt. Die Magnesiumkonzentration wurde mittels Atomabsorptionsspektrometrie (AAAnalyst 400, Perkin Elmer Inc, Waltham, USA) bestimmt.

**Tabelle 16. Management der Flächen vor Probenahme für die 1. Inkubationsreihe**

Ort	Vorfrüchte 2019-2021	N-Gesamt 2021			Boden-C (%)	CN-Ratio	Sand (%)	pH
		Mittel	Min	Max				
Halle	Winterroggen/Winterroggen/Winterroggen	30.0	0.0	60.0	1.1	13.8	72.5	5.8
Kassel	Winterraps/Winterweizen/Wintergerste	77.4	0.0	185.0	1.5	9.9	8.9	6.8
Großbeeren	Schälgurke/Porree/Sellerie	198.9	0.0	294.0	1.8	14.1	51.1	7.2
Göttingen	Winterweizen/Wintergerste/Winterraps Winterweizen/Winterweizen/Wintergerste Zuckerrübe/Winterweizen/Silomais Zuckerrübe/Silomais/Winterweizen	176.2	144.0	188.0	1.4	9.9	16.1	7.1
Harste	Winterweizen/Silomais/Winterweizen Grünland Winterweizen/Winterraps/Winterweizen	166.0	110.0	200.0	1.4	10.0	4.9	6.9
Bad Hersfeld	Winterweizen/Triticale/Wintergerste Silomais/Wintergerste/Silomais	101.2	50.0	154.0	1.1	9.6	49.5	6.4
Bad Salzungen	Winterweizen/Triticale/Silomais	133.0	0.0	250.0	0.8	10.8	66.7	5.8
Gülzow	Silomais/Triticale/Winterraps Winterweizen/Silomais/Triticale Triticale/Winterraps/Winterweizen Winterraps/Winterweizen/Silomais	179.0	0.0	251.0	0.8	10.2	75.7	6.1
Lindenhof	Winterweizen/Wintergerste/Winterraps	160.0	NA		2.1	11.1	52.2	6.3
Schuby	Silomais/Silomais/Silomais	91.2	0.0	190.0	2.7	17.6	86.2	5.5
Hohenschulen	Winterraps/Silomais/Winterweizen Winterweizen/Hafer/Winterweizen Winterweizen/Hafer/Winterroggen Winterroggen/Silomais/Winterroggen Winterroggen/Silomais/Silomais	97.0	0.0	280.0	1.4	10.6	59.6	6.6
Handrup	Silomais	200	NA		1.7	14.7	87.3	5.8
Brual	Kartoffeln/Silomais/Kartoffeln Silomais/Silomais/Silomais Winterweizen/Silomais/Winterweizen	211.0	100.0	251.0	2.5	17.7	90.4	5.0

	Triticale/Silomais/Silomais Zuckerrübe/Triticale/Silomais Zuckerrübe/Winterweizen/Winterroggen Silomais/Triticale/Kartoffeln							
Dikopshof	Zuckerrübe/Winterweizen/Winterroggen Winterweizen/Wintergerste/Silomais Silomais/Winterweizen/Wintergerste	66.7	0.0	120.0	1.0	10.4	17.4	33.0
Rauischholzhausen	Silomais/Winterweizen/Körnermais	109.0	0.0	180.0	1.0	8.9	12.4	6.9
Ladenburg	Winterweizen/Winterweizen/Silomais	80.0	0.0	200.0	1.5	11.0	29.5	7.4
Freising	Winterweizen/Sommerweizen/Wintergerste	124.5	0.0	180.0	1.1	9.0	17.2	6.2

**Tabelle 17. Management der Flächen vor Probenahme für die 2. Inkubationsreihe**

Ort	Reinshof, Göttingen	Hohenschulen, Kiel
Vorfrüchte	Wintergerste	Winterraps, Ackerbohne
	Winterraps + Winterweizen	Silomais
	Silomais	Winterweizen
N-Düngung	Ortsüblich	N0 und N 280

### Erfassung der NIRS-Spektren

Zur Ergänzung der Laboranalysen wurden zusätzliche Bodenproben getrocknet, homogenisiert, auf 1 mm gemahlen und zweimal mit Hilfe der Nahinfrarot-Reflexionsspektroskopie (NIRS) mit einem Phoenix 5000 Spektrometer (Bluesun Sci, USA) gemessen. Für die vorliegende Arbeit wurden von 1100 nm – 2498 nm in 2 nm Abständen gemessen, was je Probe zu 1400 Proben (319 Proben \* 1400 Absorptionsbänder = 446.600 Absorptionsbändern geführt hat)

### Vorverarbeitung der Spektraldaten

Die Vorverarbeitung ist entscheidend bei der Analyse von NIRS-Spektraldaten, da die Daten oft unerwünschte Störungen wie Hintergrundrauschen, überlappende Absorptionsbänder und Umwelt- oder Instrumentalfaktoren enthalten (Heil und Schmidhalter 2021). Wir haben die folgenden Vorverarbeitungsmethoden entweder einzeln oder in Kombination angewendet: Savitzky-Golay-Filterung, multiplikative Streukorrektur (MSC), Standardnormalvariante (SNV), Savitzky-Golay erste und zweite Ableitungen, Maximum-Minimum-Skalierung (Wadoux et al. 2021). Mehrere Datensätze wurden auf der Grundlage dieser verschiedenen Vorverarbeitungstechniken erstellt, die dann mithilfe der Modelle bewertet wurden, um den optimalen Ansatz zu ermitteln. Der Datensatz, der die höchste Vorhersagegenauigkeit lieferte, wurde für die weitere Analyse ausgewählt (Rinnan et al. 2009).

### Datenmodellierung, Modellauswahl und Optimierung

70-80% der Daten wurden dem Kalibrierungssatz und 30 - 20 % dem Validierungssatz zugewiesen, wobei eine stratifizierte Aufteilung verwendet wurde. Die Stratifizierung stellte sicher, dass die Kalibrierungs- und Validierungsdatensätze eine ähnliche Verteilung der Zielvariablen aufwiesen, was eine Verzerrung bei der Modellierung und Bewertung verhindert (Muon 2015). Eine Hauptkomponentenanalyse (PCA) wurde auf den Spektraldatensatz angewendet, um dessen Dimensionalität zu reduzieren und zugrunde liegende Muster zu identifizieren (Ruma et al. 2024a). Die Methode der partiellen kleinsten Quadrate-Regression (PLSR), eine multivariate statistische Technik, wurde verwendet, um die Beziehung zwischen SMNR und vorverarbeiteten NIRS-Daten zu modellieren (Samadi et al. 2020). Das Modell wurde optimiert, indem die optimale Anzahl an Komponenten mittels 10-facher Kreuzvalidierung ausgewählt wurde, um die zugrunde liegende Datenstruktur zu erfassen und gleichzeitig die Dimensionalität zu reduzieren (Au et al. 2020; Sarkar et al. 2020). Anschließend wurde eine reduzierte Anzahl an Komponenten ( $n_{comp} = 10$ ) gezielt ausgewählt, um das Modell zu vereinfachen und möglicherweise die Generalisierbarkeit zu verbessern. Obwohl PLSR weit verbreitet ist für die Spektralanalyse, begrenzt seine Abhängigkeit von Linearität die Anwendbarkeit in Szenarien, in denen die zugrunde liegenden Beziehungen komplex oder nicht-linear sind (Fidêncio et al. 2002). In Anbetracht dessen wurden auch nicht-lineare Modellierungsansätze untersucht: Random Forest (RF), Support Vector Machine (SVM) mit einem Radial Basis Function (RBF)-Kern, Künstliche Neuronale Netze (ANN) und Extreme Gradient Boosting (XGBoost) (Cui und Fearn 2017; Santana et al. 2021; Mireei et al. 2014; Oliveira et al. 2024; Zayani et al. 2023; Sim et al. 2024).

Der Random Forest (RF)-Algorithmus, entwickelt von Breiman (2001), ist eine Ensemble-Lernmethode, die weit verbreitet für Klassifikations- und Regressionsaufgaben eingesetzt wird (Lee et al. 2013). Der Algorithmus funktioniert, indem er eine Vielzahl von Entscheidungsbäumen unter Verwendung von Bootstrapped-Proben der Trainingsdaten konstruieren lässt, wobei jeder Baum durch zufällige Auswahl von Prädiktoren an jedem Knoten wächst. Die Vielfalt der Bäume, die durch Bootstrapping (Bagging) und zufällige Merkmalsauswahl

gewährleistet wird, trägt zur Robustheit des Modells bei (Colopietro et al. 2025; He et al. 2022). RF-Modelle bieten mehrere Vorteile, darunter eine verbesserte Vorhersagegenauigkeit, reduzierte Überanpassung, Unempfindlichkeit gegenüber fehlenden Daten und Multikollinearität sowie die Fähigkeit, große Datensätze zu verarbeiten, die sowohl quantitative als auch qualitative Variablen umfassen. Umfassende mathematische Beschreibungen des Random Forest-Algorithmus sind in der bestehenden Literatur verfügbar (Bauer und Kohavi 1999; Breiman 2001; Breiman et al. 2017; Hastie et al. 2009). In dieser Studie wurde das Random Forest-Modell mit dem randomForest-Paket in R genutzt. Hyperparameter, einschließlich der Anzahl der Bäume (ntree) und der Anzahl der zufällig ausgewählten Merkmale bei jeder Aufspaltung (mtry), wurden unter Verwendung der 5-fachen Kreuzvalidierung über das ‚caret‘-Paket (Kuhn 2011) optimiert. Insgesamt wurden 500 Bäume gebildet, um die Modellstabilität zu erhöhen, und mtry wurde innerhalb eines vordefinierten Bereichs (50 bis 200) abgestimmt, um die optimale Konfiguration zu ermitteln. Zudem wurde der nodesize-Parameter auf 10 gesetzt, um die Baumtiefe zu steuern und Überanpassung zu verhindern. Abschließend wurde eine Merkmalsbedeutungsanalyse durchgeführt, um die einflussreichsten Spektralvariablen zu bestimmen, die zu den Modellvorhersagen beitragen.

Support Vector Machine (SVM) ist eine leistungsstarke Kernel-basierte Methode des maschinellen Lernens, die von Vladimir N. Vapnik eingeführt wurde und sich zu einem weit verbreiteten Werkzeug für die Analyse komplexer, hochdimensionaler Daten entwickelt hat (Cortes und Vapnik 1995). Dieses Modell projiziert die Eingangsdaten in einen hochdimensionalen Merkmalsraum mittels einer Kernel-Funktion. Die Wahl des Kerns ist entscheidend für die Leistung des Modells, da sie die Transformation der Daten definiert und die Fähigkeit des SVM beeinflusst, zu generalisieren (Cortes und Vapnik 1995). Unter den verschiedenen Kernel-Funktionen ist der Radial Basis Function (RBF)-Kern besonders effektiv, um nicht-lineare Beziehungen in den Daten zu erfassen. Durch das Abbilden der Datenpunkte in einen transformierten Merkmalsraum etabliert der RBF-Kern eine flexible Entscheidungsgrenze, die sich gut an subtile Datenvariationen anpasst (Santana et al. 2021; Devos et al. 2009). In dieser Studie wurde der Radial-Basis-Kern verwendet. Eine detaillierte mathematische Beschreibung des SVM-Modells mit RBF-Kern ist in der bestehenden Literatur zu finden (Barea-Sepúlveda et al. 2022; Cortes und Vapnik 1995; Santana et al. 2021). Um das Modell zu optimieren, wurde eine 10-fache Kreuzvalidierung auf den Trainingsdaten durchgeführt. Während dieses Prozesses wurde eine Hyperparameter-Abstimmung über fünf Werte des Regularisierungsparameters (C) und der Kernel-Breite ( $\sigma$ ) mittels einer Grid-Search-Methode durchgeführt. Nach der Kreuzvalidierung wurde das beste Modell basierend auf seiner Leistung auf den Trainingsdaten ausgewählt, und das endgültige SVM-Modell wurde mit den optimalen Hyperparametern trainiert. Das Modell wurde dann mit dem unabhängigen Validierungsdatensatz getestet, um seine Generalisierungsfähigkeit zu beurteilen.

Extreme Gradient Boosting (XGBoost), eingeführt von Chen und Guestrin (2016), ist eine fortschrittliche Implementierung des Gradient-Boosting-Rahmenwerks. XGBoost verbessert die prädiktive Genauigkeit, indem es schrittweise mehrere schwache Lernmodelle zu einem robusten Ensemble-Modell zusammenführt, was es sowohl für Regressions- als auch Klassifikationsaufgaben geeignet macht (Chen und Guestrin 2016). Ein Schlüsselement von XGBoost ist die Integration von Regularisierungsbegriffen und Straf-Funktionen innerhalb der Ziel-Funktion, um die Modellkomplexität zu steuern und so Varianz, Verzerrung und Überanpassung zu mildern (Tang et al. 2025). Der schnelle Trainingsalgorithmus und die Unterstützung verschiedener Hyperparameter-Abstimmungsoptionen verbessern zusätzlich die Anpassungsfähigkeit und Leistung (Chen und Guestrin 2016; Wang et al. 2024; Zhang et al. 2023; Zou et al. 2024). Die Optimierung und Leistung eines XGBoost-Modells werden maßgeblich durch die Auswahl und Abstimmung der Hyperparameter beeinflusst, die die Lernprozesse und prädiktiven Eigenschaften des Modells steuern (Alam et al. 2025). In dieser Studie wurden wichtige Hyperparameter optimiert, um die Modellleistung zu verbessern. Eine 10-fache Kreuzvalidierung wurde mit frühem Stopp nach 50 Runden durchgeführt, um die optimale Anzahl an Boosting-Iterationen zu bestimmen (Dhaliwal et al. 2018; He et al. 2022; Ye et al. 2023; Zou et al. 2024).

Künstliche neuronale Netze (ANNs), inspiriert vom menschlichen Gehirn, sind maschinelle Lernalgorithmen, die entwickelt wurden, um Muster zu erkennen und Vorhersagen zu treffen, indem sie aus Daten lernen (Park und Lek 2016). Sie bestehen aus miteinander verbundenen Knoten (Neuronen), die in Schichten organisiert sind: der Eingabeschicht, den versteckten Schichten und der Ausgabeschicht. Daten werden in die Eingabeschicht eingespeist, von den versteckten Schichten verarbeitet und die Vorhersagen werden durch die Ausgabeschicht getroffen (Inglis et al. 2024). Das in dieser Studie verwendete Modell ist ein Feedforward-Künstliches Neuronales Netzwerk (ANN), ein Einzel-Schicht-Perzeptron (SLP), das für Regressionsaufgaben ausgelegt ist. Das Netzwerk nimmt die ersten 30 Hauptkomponenten (PCA) auf, die aus den Spektraldaten abgeleitet wurden, wobei jede Hauptkomponente einem Eingabeneuron entspricht. Es enthält eine einzelne versteckte Schicht, deren Anzahl an Neuronen durch Hyperparameter-Abstimmung optimiert wird, getestet mit den Größen 3 und 5. Neuronen in der versteckten Schicht wenden eine nichtlineare Aktivierungsfunktion (Sigmoid) an, während die Ausgabeschicht aus einem einzigen Neuron mit einer linearen Aktivierungsfunktion besteht, das den kontinuierlichen Wert der SMNR vorhersagt. Das Modell wird mit Backpropagation trainiert, einem überwachten Lernalgorithmus, bei dem der Ausgabefehler rückwärts durch das Netzwerk propagiert wird, um die Gewichtungen mittels Gradientenabstieg zu aktualisieren. Die Leistung des Netzwerks wird mittels 10-facher Kreuzvalidierung bewertet, wobei die Komplexität der Architektur durch Anpassung der Anzahl der Neuronen in der versteckten Schicht und der Stärke der Regularisierung kontrolliert wird. Diese

Konfiguration ermöglicht es dem Modell, komplexe Muster aus den Spektraldaten zu lernen, gut auf neue Daten zu verallgemeinern und genaue Vorhersagen zu treffen.

In der prädiktiven Modellierung ist das Modellensemble eine ausgeklügelte Technik, die entwickelt wurde, um die Vorhersagegenauigkeit zu steigern, indem die Ausgaben mehrerer Basismodelle kombiniert werden (Guan et al. 2025). Eine der effektivsten Ensemble-Methoden ist das Stacking-ensemble-Lernen, das mehrere Basismodelle und einen Meta-Lerner in einer zweischichtigen verschachtelten Struktur kombiniert. Bei diesem Ansatz werden unterschiedliche Basismodelle unabhängig auf dem gleichen Datensatz trainiert, um Vorhersagen zu erzeugen, die dann als Eingaben für den Meta-Lerner verwendet werden. Dieser Meta-Lerner kombiniert die Vorhersagen der Basismodelle, um eine endgültige, genauere Vorhersage zu treffen (Guan et al. 2025; Moon et al. 2020). Angesichts des begrenzten Datensatzes in dieser Studie wurde die gestapelte Ensemble-Methode eingesetzt, um die Schätzgenauigkeit der Boden-N-Mineralisierungsrate unter Verwendung der komplementären Stärken mehrerer maschineller Lernmodelle, einschließlich Support Vector Machines (SVM), Extreme Gradient Boosting (XGBoost) und Künstliche Neuronale Netze (ANN), zu verbessern. Random Forest (RF) wurde von diesem Ensemble ausgeschlossen, da es zwar als Basismodell während der Kalibrierung gut abschloss, aber seine Validierungsleistung deutlich niedriger war, was darauf hinweist, dass es Schwierigkeiten hatte, auf nicht gesehene Daten zu generalisieren. Zunächst wurde jedes Basismodell unabhängig auf dem Datensatz trainiert, um Einzelvorhersagen zu erzeugen. Anschließend wurde eine Stacking-Technik angewendet, bei der die Vorhersagen dieser Basismodelle als Eingabefeatures für ein Meta-Modell dienten. Das Meta-Modell wurde mit einer 10-fachen Kreuzvalidierung trainiert, um die Generalisierbarkeit sicherzustellen und Überanpassung zu minimieren.

### Leistungsbewertung der entwickelten Modelle

Die Leistung der Modelle zur Vorhersage der SMNR wurde unter Verwendung von Kalibrierungs- und Validierungsdatensätzen evaluiert (Wang et al. 2018). Das Bestimmtheitsmaß ( $R^2$ ) wurde berechnet, um den Anteil der Varianz der vorhergesagten Mineralisierungsraten zu bewerten, der durch jedes Modell erklärt wird. Zusätzlich haben wir den Root Mean Squared Error (RMSE) berechnet, um die durchschnittliche Größe der Vorhersagefehler zu quantifizieren. Niedrigere RMSE-Werte weisen auf eine überlegene Modelleistung hin, was auf kleinere Abweichungen zwischen den vorhergesagten und beobachteten SMNR hinweist. Die Residual Prediction Deviation (RPD) wurde ebenfalls berechnet, um eine robuste Bewertung der Modelle zu ermöglichen, indem sowohl die Variabilität der beobachteten Daten als auch der Vorhersagefehler berücksichtigt wurden. Höhere RPD-Werte deuten auf eine überlegene Vorhersagefähigkeit hin. Schließlich haben wir das Verhältnis der Leistung zum Interquartilsabstand (RPIQ) verwendet, um die Robustheit der Modelle gegenüber Schwankungen der SMNR zu bewerten.

### Ergebnisse und Diskussion

Die deskriptive Analyse der chemischen Bodenparameter zeigte eine erhebliche Variabilität zwischen den Proben (Tabelle 18). Die Stickstoffmineralisierungsrate (SMNR) hatte einen Durchschnitt von 0.14 kg N/ha/Tag, mit Werten, die von -0.57 bis 1.57 kg N/ha/Tag reichten, und einem hohen Variationskoeffizienten (CV) von 297.95 %, was auf eine erhebliche Heterogenität in den Stickstoffdynamiken hinweist. Einige Proben wiesen negative SMNR-Werte auf, was auf N-Immobilisation hinweist, die wahrscheinlich mit dem Kohlenstoff-zu-Stickstoff-Verhältnis (C:N) zusammenhängt, das im Durchschnitt 11.10 betrug (Bereich 4.10 - 21.87). Höhere C:N-Verhältnisse in einigen Proben können die N-Verfügbarkeit einschränken und die Immobilisierung fördern. Nicolardot et al. (2001) stellten fest, dass bei C:N-Verhältnissen über 25 immer eine Netto N-Immobilisierung auftritt, während eine Netto N-Mineralisation bei Verhältnissen unter 15 beobachtet wird. Der Gehalt an organischer Substanz im Boden (SOM) lag im Durchschnitt bei 2.25 % (Wertebereich 0.23 - 6.07 %) und könnte ebenfalls die N-Dynamik beeinflussen. Höhere SOM-Werte bieten mehr Substrat für mikrobielle Aktivität, was die Mineralisierung fördert, während niedrigere Werte diese einschränken können (Soinne et al. 2021). Dies wird von Ros et al. (2011) unterstützt, die feststellten, dass organische Substanz 78 % der Variation des mineralisierbaren N erklärte. Die anfänglichen N<sub>min</sub>-Mengen lagen im Durchschnitt bei 33.01 kg/ha (Range: 1 - 212 kg/ha), wobei niedrigere N<sub>min</sub>-Werte möglicherweise zur N-Begrenzung und Immobilisierung beitragen, während höhere Werte eine aktive Mineralisierung unterstützen könnten. Der pH-Wert des Bodens reichte von 4.3 bis 7.8, mit einem Durchschnitt von 6.58. Niedrigere pH-Werte, insbesondere solche nahe 4.3, könnten die N-Mineralisierung einschränken, indem sie die Löslichkeit von organischem N und die mikrobielle Aktivität verringern. Dies steht im Einklang mit den Ergebnissen von Curtin et al. (1998), die beobachteten, dass die Erhöhung des pH-Werts in leicht sauren Böden die N-Mineralisation anregte. Textur, Feuchtigkeit und Temperatur sind ebenfalls häufig nichtlinear mit den N-Dynamiken verbunden (Rodrigo et al. 1997; Ruma et al. 2024a). Insgesamt scheint die Variabilität der SMNR von einem komplexen Zusammenspiel aus organischer Substanz im Boden, N-Verfügbarkeit, mikrobiellem Nährstoffbedarf und pH-Wert beeinflusst zu werden, was sowohl Mineralisierung als auch Immobilisierung in verschiedenen Bodenproben zur Folge hat.

**Tabelle 18. Deskriptive Statistiken für die Bodenparameter, einschließlich der Stickstoffmineralisierungsrate (SMNR), der absoluten Stickstoffmineralisierung (delta), des Gehalts an organischer Substanz (SOM), des Kohlenstoff-zu-Stickstoff-Verhältnisses (CN\_ratio) und des initialen mineralischen Stickstoffs (N<sub>min</sub>) vor der Inkubation, sind unten zusammengefasst. Die Statistiken**

umfassen die Anzahl der Proben (n), den Mittelwert, den Bereich, die Standardabweichung (SD) und den Variationskoeffizienten (CV).

Zielgröße	Mittelwert	Min	Max	SD	CV (%)
SMNR (kg N/ha/day)	0.14	-0.57	1.57	0.42	297.95
Delta (kg N/ha)	14.13	-57	157	42.10	297.95
SOM (%)	2.25	0.23	6.07	0.97	43.08
CN_ratio	11.10	4.10	21.87	2.74	24.65
Initial Nmin (kg/ha)	33.01	1	212	22.50	68.17
Soil pH	6.58	4.3	7.8	0.61	9.34

### Vergleich verschiedener Spektralvorverarbeitungsmethoden

Um die spektralen Eigenschaften zu verbessern und die Beziehung zwischen spektralen Daten und der SMNR im Boden zu optimieren, wendeten wir verschiedene Vorverarbeitungstechniken an. Abbildung 36 zeigt sowohl die Rohdaten der NIRS-Spektren als auch die entsprechenden Daten nach der Vorverarbeitung. Das Spektraldiagramm zeigt einen allgemeinen Rückgang der Absorption im Bereich von 1100 - 1400 nm, 1500 - 1900 nm und 1950 - 2150 nm, während ein steigender Trend zwischen 2200 nm und 2450 nm beobachtet wird. Auffällige Spitzen erscheinen bei 1900 - 1950 nm, um 2200 nm und eine kleinere Spitze nahe 1400 nm, mit einem Abfall bei etwa 2150 nm. Die beobachteten spektralen Merkmale in unserer Untersuchung stimmen mit bekannten NIR-Absorptionsmustern von Bodenbestandteilen überein. Die Spitzen bei 1400 nm und 1900 - 1950 nm zeigen eine starke Lichtabsorption in diesen Wellenlängenbereichen, was häufig mit Wasser im Boden assoziiert wird (Stenberg et al. 2010). Andere Spitzen und Täler könnten mit anderen Bodenbestandteilen wie Tonmineralien oder Karbonaten in Verbindung stehen, die ebenfalls die spektrale Reaktion beeinflussen können. Beispielsweise fanden Asgari et al. (2020) heraus, dass das Vorhandensein von Karbonaten im Boden mit spezifischen spektralen Signaturen verbunden ist, wie etwa Absorptionsmerkmalen um 2338 nm.

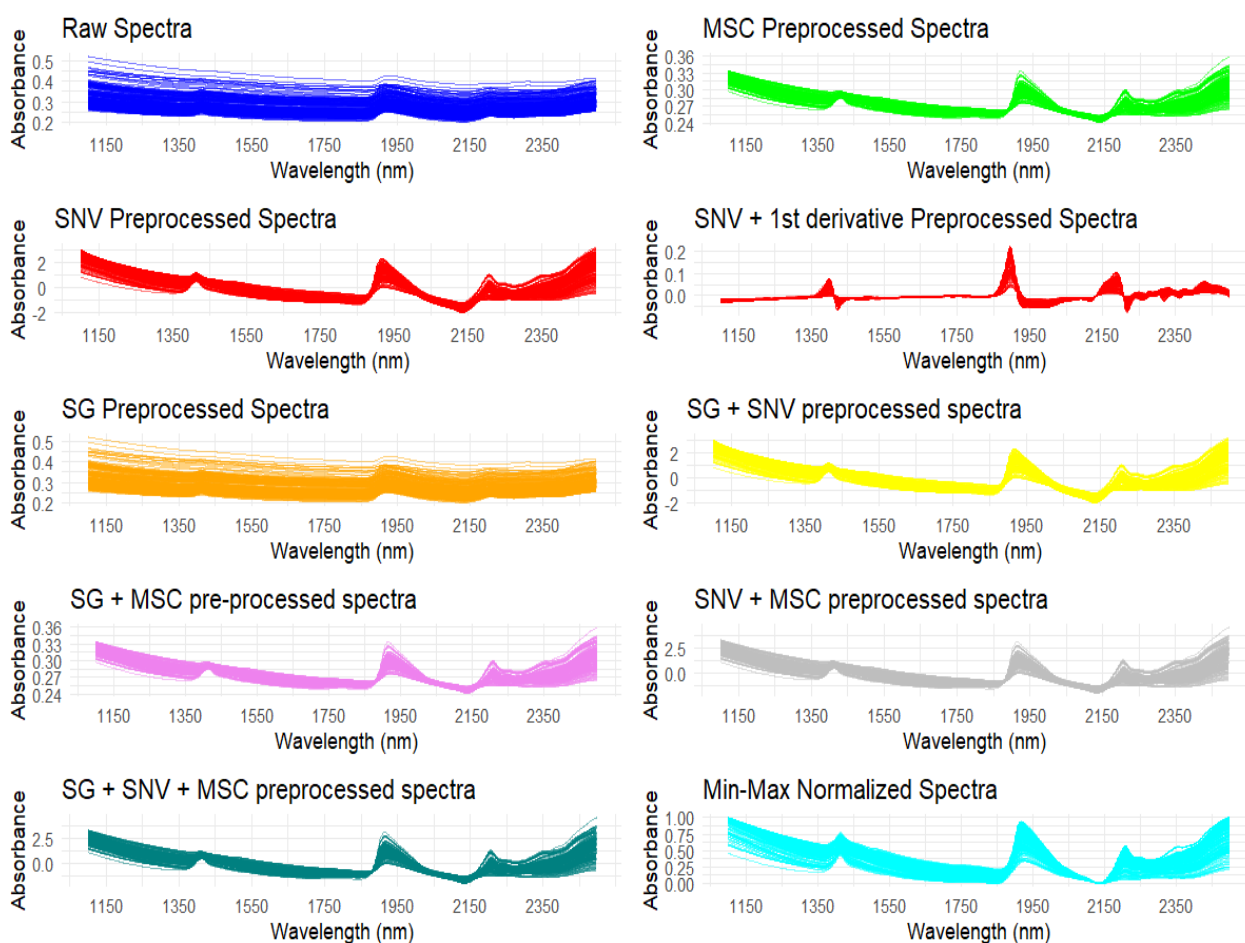


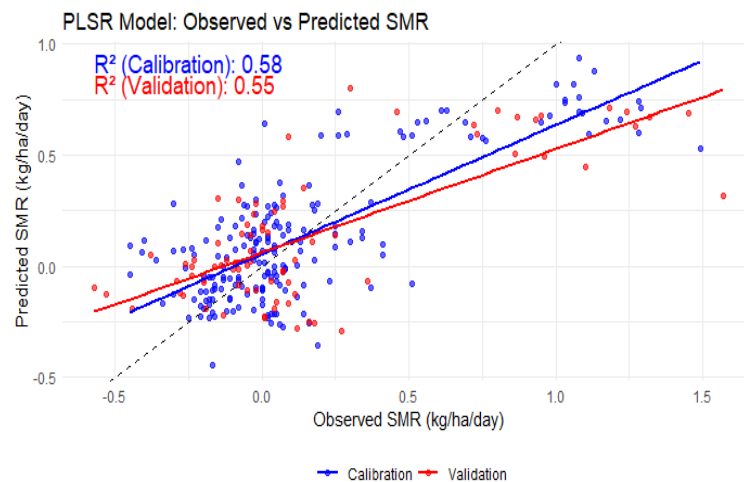
Abbildung 36. Vor-prozessierte Spektraldaten für unterschiedliche Modelle

### Vergleich linearer und nichtlinearer Modelle zur Vorhersage der Stickstoffmineralisierung aus Spektraldaten

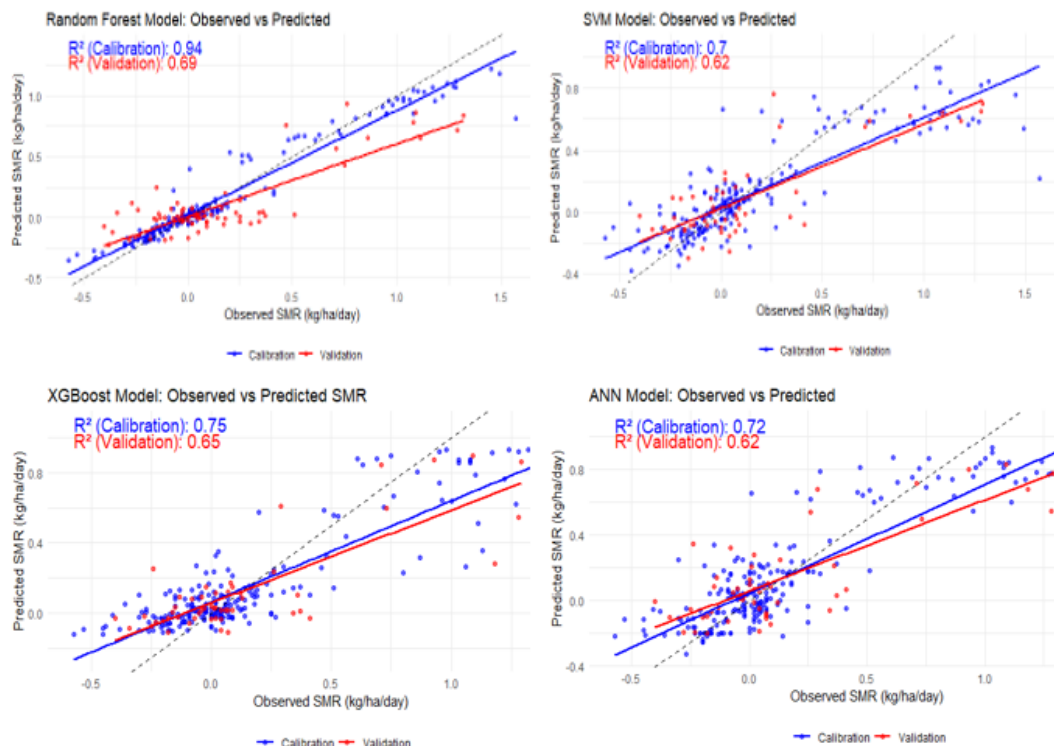
Abbildung 37 zeigt die Leistung eines Partial Least Squares Regression (PLSR)-Modells bei der Vorhersage der SMNR. In der Kalibrierungsphase zeigt die Regressionslinie einen positiven Trend, was darauf hinweist, dass das Modell einen Teil der Variabilität in den Trainingsdaten erfasst. Die Abweichung von der idealen 1:1-

Linie deutet jedoch auf ungenaue Vorhersagen hin. Diese Abweichung nimmt in der Validierungsphase zu, was auf eine verringerte Vorhersagekraft bei unbeobachteten Daten hinweist. Obwohl das Modell die allgemeinen Trends erfasst, zeigen die verstreuten Datenpunkte, dass die linearen Annahmen von PLSR die Komplexität der SMNR möglicherweise nicht vollständig erfassen.


Im Gegensatz dazu zeigt Abbildung 38 die Beziehung zwischen beobachteten und vorhergesagten SMNR für die nichtlinearen Modelle. Im Vergleich zu PLSR weisen die maschinellen Lernmodelle sowohl in der Kalibrierungs- als auch in der Validierungsphase eine bessere Übereinstimmung mit der idealen 1:1-Linie auf, wenn auch mit unterschiedlichen Generalisierungsgraden in der Validierungsphase. In der Kalibrierungsphase zeigt das RF-Modell eine enge Clusterung um die 1:1-Linie, jedoch eine größere Abweichung in der Validierungsphase. Die Modelle SVM, XGBoost und ANN folgen einem ähnlichen Muster und stimmen gut mit den beobachteten Werten überein. In der Validierungsphase zeigen diese Modelle jedoch weniger Abweichungen als RF, was auf eine bessere Generalisierbarkeit und verbesserte Vorhersage-Stabilität hinweist. Die kleinere Lücke zwischen den Kalibrierungs- und Validierungsergebnissen unterstreicht die Robustheit dieser Modelle. Schließlich übertrifft der gestapelte Ensemble-Ansatz, der in Abbildung 39 dargestellt ist, sowohl PLSR als auch einzelne maschinelle Lernmodelle, was wahrscheinlich auf die Kombination mehrerer Algorithmen mit einem Meta-Lerner zurückzuführen ist, der die Modellstabilität verbessert und Verzerrungen verringert.



**Abbildung 37. Beobachtete vs. vorhergesagte Stickstoffmineralisierungsrate unter Verwendung des Partial Least Squares Regression (PLSR)-Modells.**



**Abbildung 38. Beobachtete vs. vorhergesagte Stickstoffmineralisierungsrate unter Verwendung verschiedener Machine Learning-Modelle.**



**Abbildung 39. Beobachtete vs. vorhergesagte Stickstoffmineralisierungsrate unter Verwendung des gestapelten Ensemble-Modells, das SVM, XGBoost und ANN kombiniert.**

### Modellvergleiche

Tabelle 19 vergleicht die prädiktive Leistung von PLSR mit anderen nichtlinearen Modellen unter Verwendung statistischer Kennzahlen und gibt auch den Vergleich der durchschnittlichen Stickstoffmineralisierungs-/Immobilisierungs-Raten, die von jedem Modell vorhergesagt wurden.

**Tabelle 19. Vergleich der Ergebnisse der Bewertungskennzahlen für 4 Modelle und eine Ensemble-Lernmethode sowie der durchschnittlich vorhergesagten Stickstoffmineralisierung.**

Name	Kalibration				Validation			
	R <sup>2</sup>	RMSE	RPD	RPIQ	R <sup>2</sup>	RMSE	RPD	RPIQ
PLSR	0.58	0.25	1.55	1.14	0.55	0.33	1.47	0.90
RF	0.94	0.11	3.99	2.63	0.69	0.21	1.80	1.44
SVM	0.70	0.23	1.84	0.47	0.62	0.25	1.63	1.08
XGBoost	0.75	0.23	1.84	1.28	0.65	0.25	1.65	1.07
ANN	0.72	0.22	1.90	1.31	0.62	0.25	1.64	1.06
Stacked ensemble (SVM + XGBoost + ANN)	0.79	0.20	2.16	1.49	0.70	0.22	1.84	1.19

Im Kalibrierungsdatensatz erreichte PLSR ein R<sup>2</sup> von 0.58, mit einem RMSE von 0.25, einem RPD von 1.55 und einem RPIQ von 1.14. Diese Kennzahlen deuten auf eine moderate Anpassung an die Kalibrierungsdaten hin, aber die Leistung von PLSR wird von mehreren maschinellen Lernmodellen übertroffen. Besonders das Random Forest (RF)-Modell zeigte eine überlegene Leistung mit einem R<sup>2</sup> von 0.94, einem deutlich niedrigeren RMSE von 0.11, einem höheren RPD von 3.99 und einem höheren RPIQ von 2.63. Dies deutet darauf hin, dass RF die Variabilität in den Kalibrierungsdaten besser erfasst als PLSR. Die maschinellen Lernmodelle, einschließlich SVM, XGBoost und ANN, erzielten ebenfalls gute Ergebnisse in der Kalibrierung, mit R<sup>2</sup>-Werten von 0.70 bis 0.75, RMSE-Werten von etwa 0.22 bis 0.23 und RPD-Werten von etwa 1.8. Diese Modelle zeigten eine gute Übereinstimmung mit den beobachteten Werten, und ihre Leistung war stabiler als die von PLSR. Das gestapelte Ensemble, das SVM, XGBoost und ANN kombinierte, erzielte ein R<sup>2</sup> von 0.79, ein RMSE von 0.20, ein RPD von 2.16 und ein RPIQ von 1.49, was weiter zeigt, dass der Ensemble-Ansatz die prädiktive Genauigkeit verbessert.

Im Evaluierungsdatensatz nahm die Leistung von PLSR ab, mit einem R<sup>2</sup> von 0.55, einem RMSE von 0.33, einem RPD von 1.47 und einem RPIQ von 0.90, was auf eine reduzierte Fähigkeit hinweist, auf ungesehene Daten zu generalisieren. Im Gegensatz dazu behielten die maschinellen Lernmodelle eine bessere Übereinstimmung mit den beobachteten Werten. RF zeigte die beste Leistung mit einem R<sup>2</sup> von 0.69, einem RMSE von 0.21, einem RPD von 1.80 und einem RPIQ von 1.44. Auch die SVM-, XGBoost- und ANN-Modelle zeigten solide Leistungen in der Validierung, mit R<sup>2</sup>-Werten von 0.62 bis 0.65 und RMSE-Werten zwischen 0.25 und 0.33. Diese Modelle wiesen im Vergleich zu RF eine geringere Abweichung auf, was auf eine bessere Generalisierungsfähigkeit hinweist. Schließlich erzielte das gestapelte Ensemble ein R<sup>2</sup> von 0.70, ein RMSE von 0.22, ein RPD von 1.84 und ein RPIQ von 1.19 und zeigte damit eine ähnliche Leistung wie RF, was darauf hinweist, dass der Ensemble-Ansatz im Vergleich zu den einzelnen Modellen zur verbesserten Generalisierung beigetragen hat.

Maschinelle Lernmodelle übertreffen demnach in der Regel PLSR, insbesondere in der Validierung, was möglicherweise auf ihre Fähigkeit hinweist, komplexe, nichtlineare Beziehungen zu erfassen. Interessanterweise berichteten Ruma et al. (2024a) von erfolgreichen PLSR-Anwendungen zur Vorhersage

der SNMR aus vis-NIR-Daten, allerdings unter anderen Bedingungen. In unserer Studie hätte eine Aufteilung der Proben nach Textur möglicherweise die Genauigkeit von PLSR verbessert, jedoch die verfügbare Datengröße für maschinelle Lernmodelle reduziert, die in der Regel bei größeren Stichprobenmengen am besten abschneiden (Bailey et al. 2022). Eine verwandte Studie desselben Autors (Ruma et al. 2024a, 2024b) untersuchte, ob die Kombination von Hilfsvariablen wie Gesamtstickstoff (TN), Gesamtkohlenstoff (TC) und elektrischer Leitfähigkeit (EC) mit vis-NIR-Daten die Vorhersage von SNMR verbessern könnte. Obwohl einige moderate Verbesserungen beobachtet wurden, waren die Ergebnisse in verschiedenen Feldern inkonsistent. Ebenso zeigte diese Studie, dass die Einbeziehung von Bodenattributen wie organischer Masse und dem CN-Verhältnis im Boden die Vorhersagegenauigkeit nicht signifikant verbesserte. Dies könnte an den nichtlinearen Beziehungen zwischen diesen Variablen und der SNMR liegen.

Die inhärente Variabilität der Bodenmerkmale, die komplexen Wechselwirkungen zwischen biologischen und chemischen Prozessen, die die N-Dynamik beeinflussen, sowie die Möglichkeit, dass Spektraldaten nur einen Teil relevanter Informationen erfassen, könnten alle eine bedeutende Rolle spielen. Zudem könnte die Anwesenheit sowohl positiver als auch negativer Nmin-Werte (die sowohl Mineralisierung als auch Immobilisierung anzeigen) die Modellierungsbemühungen erschweren, da die zugrunde liegenden Mechanismen, die diese gegensätzlichen Prozesse antreiben, möglicherweise nicht effektiv von den Spektraldaten erfasst werden. Alle Modelle sagten die mittlere Immobilisierung im Boden voraus. Dieses Phänomen lässt sich wahrscheinlich auf den Zeitpunkt der Bodenentnahme im Winter zurückführen. Bis zum Winter hätte ein Großteil der mikrobiellen Aktivität und des N-Kreislaufs im Oberboden bereits im Feld unter dem Einfluss von klimatischen und biologischen Faktoren wie Temperaturschwankungen, Niederschlägen und der Zersetzung von Pflanzenresten stattgefunden. Diese Vor-Proben-Feldprozesse könnten die N-Pools und mikrobiellen Dynamiken erheblich verändert haben und Variabilität erzeugt haben, die die Vorhersage der SNMR erschweren.

Aus ungedüngten Parzellen im Feldversuch von AP1 wurden Bodenproben entnommen und mittels NIRS gemessen, um eine spektrale Vorhersage der SNMR zu erstellen. Die SNMR wurde definiert als N-Aufnahme in der ungedüngten Variante und der Änderung von Nmin-Mengen zwischen Frühjahr und Maisernte. Es zeigte sich, dass die auf Laborinkubation beruhenden in AP4 entwickelten Modelle, die im Feld ermittelte SNMR nicht schätzen können. Offensichtlich kommt es im Feld durch die Anwesenheit von wachsendem Mais, durch diurnale Temperaturschwankungen zu erheblichen Unterschieden in der SNMR im Vergleich zur Laborinkubation, die unter konstanten Temperatur- und Feuchtebedingungen durchgeführt wurde.

## **Schlussfolgerung**

Auf Grundlage des Datensatzes kann geschlussfolgert werden, dass sich NIRS unter Verwendung geeigneter Vorhersagemethoden die Stickstoffmineralisierung im Boden schätzen lässt. Allerdings bestehen enge Grenzen und eine Gültigkeit kann nur für die im Projekt erhobenen Messwerte angenommen werden.

## **Arbeitspaket 5: Modellgestützte Analyse, Entwicklung einer optimierten N-Strategie**

Ausgangspunkt der Arbeiten in AP5 war ein an der CAU im Rahmen einer Dissertation (Wienforth 2011) entwickeltes prozess-basiertes Silomaismodell. Das Modell basiert auf Feldversuchen des BiogasExpert-Projektes. In diesen wurde lediglich eine Silomaisreifegruppe untersucht. Zudem berücksichtigt das Modell zwar Trockenstress, aber kein N-Stress. Und viele der damals durchgeführten Parametrisierung entsprechen nicht mehr dem Stand der Wissenschaft. So schlugen beispielsweise Ratjen et al. (2018) basierend auf denselben Daten eine andere Berechnung der Blattfläche aus der Blattockenmasse vor. Seit der Dissertation von Frau Wienforth wurde ein Modellansatz zur Abbildung von N-Stress entworfen, jedoch betrachtet dieser nur die Gesamtpflanze anstatt die einzelnen Pflanzenorgane und wurde noch nicht evaluiert. Darauf basierend können die Tasks von AP5 in drei Teilziele unterteilt werden:

- (1) Auf- und Überarbeitung des Prozessmodells im Hinblick auf die Ertragsbildung ohne N-Stress,
- (2) Auf- und Überarbeitung des Prozessmodells im Hinblick auf die Ertragsbildung mit N-Mangel zur Prognose des N-Bedarfs. Zu den Betrachtungen des zweiten Teilziels gehören die Einbindung der Ergebnisse aus AP3 zu Effekten der Standort- und Managementparameter auf die N-Nettomineralisation.
- (3) Nutzung des Modells zur Evaluierung der Prognose des Ertrags und des N-Düngebedarfs zum 8-Blattstadium.


## **Arbeitspaket 5, Teil 1: Auf- und Überarbeitung des Prozessmodells im Hinblick auf die Ertragsbildung ohne N-Stress**

Bereits zu Beginn der Arbeiten in AP5 wurde ersichtlich, dass die in AP1 in den Jahren 2021 und 2022 erhobenen Felddaten nicht sämtliche für die Ertragsbildung relevanten Prozesse abbilden, insbesondere das Wurzelwachstum. Eine enge Zusammenarbeit mit dem parallel an der CAU laufenden RootWayS-Projekt und der darin arbeitenden Doktorandin Katja Holzhauser konnte diese Datenlücke jedoch füllen - in diesem Projekt wurden in den Jahren 2021 und 2022 auf dem Versuchsgut Hohenschulen der CAU umfangreiche Wurzelndaten im Silomais erhoben.

Mit den Arbeiten an der Reparametrisierung der Modellparameter wurde entsprechend dem ursprünglichen Zeitplan bereits in 2021 begonnen. Die Modellfertigstellung erfolgte jedoch erst stark verzögert, statt wie vorgesehen im September 2022, erst im ersten Quartal 2024. Grund hierfür waren die erst nach der Ernte im Oktober 2022 vollständig vorliegenden Versuchsdaten und der deutlich höhere Arbeitsaufwand in der Auf- und Überarbeitung des Prozessmodells. Mittlerweile ist das Ertragsmodell jedoch voll funktionsfähig und wird in Kürze veröffentlicht werden (Holzhauser et al. „HUME-Maize: A dynamic crop growth model for silage maize (*Zea mays*)“, under review).

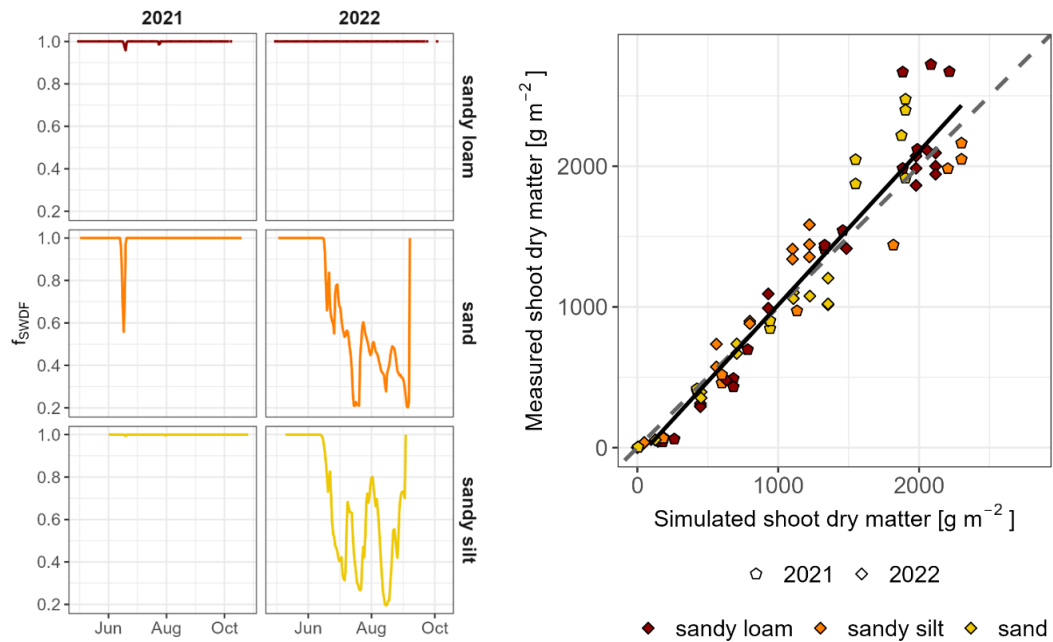
Die Ertragsbildung in HUME-Maize basiert auf einer Umwandlung der aufgenommenen Strahlung. Eine neu parametrisierte potentielle Lichtnutzungseffizienz wird hierbei durch einen Bodenwasserdefizitfaktor reduziert um den Effekt von Trockenstress abzubilden. Die aufgenommene Strahlung hängt neben der Witterung vom GAI ab. Dieser wird aus der vorhandenen Trockenmasse berechnet. In Tagesschritten wird so aus der aktuellen Witterung, der Bestandesentwicklung und dem Bodenwasserhaushalt eine Trockenmassezunahme berechnet, die dann in die einzelnen Organe verteilt wird und als Berechnungsgrundlage für den nächsten Tag dient. Bei ausbleibenden Regenfällen wird die Transpiration und die damit verbundene Wasseraufnahme über die Wurzeln aus dem Boden den Bodenwasserspeicher reduzieren und so zu einer Reduzierung des Bodenwasserdefizitfaktors und somit der Lichtnutzungseffizienz führen.

Die Entwicklung des Silomaisbestandes bestimmt hierbei die Verteilung der Biomasse in die verschiedenen Pflanzenorgane. Wie bereits beschrieben, war das von Wienforth (2011) entwickelte Modell nur auf eine Silomaisreifegruppe ausgelegt. Die für die Phänologie relevanten Parameter waren zudem standort-spezifisch kalibriert. Dies wurde nun insofern überarbeitet, als dass die von Bignon (1990) auf der Grundlage von europaweiten Untersuchungen ermittelten Temperatursummen für die Entwicklung von Silomais in das Modell eingebaut wurden. Da Bignon (1990) unterschiedliche Werte für verschiedene Reifegruppen bereitstellt, ist nun auch die Modellierung verschiedener Silomaisorten problemlos möglich. Mit diesen Literaturwerten konnte die phänologische Entwicklung an den verschiedenen Versuchsstandorten in 2021 und 2022 sehr gut beschrieben werden (Abbildung 40). Auch die frühere Abreife auf den Standorten Bad Hersfeld und Wehen in 2022 durch die hohen Temperaturen und ausbleibenden Regen wurde gut abgebildet (Abbildung 40).



**Abbildung 40: Modellierter phänologischer Entwicklung und im Feld erfasste Entwicklungsstadien (BBCH-Skala nach Lancashire et al. (1991)) der mittelfrühen Reifegruppe in den beiden Versuchsjahren an den drei Versuchsstandorten (dunkelrot = Hohenschulen, orange = Bad Hersfeld, gelb = Wehen). (erstellt von K. Holzhauser)**

Im Hinblick auf das Trockenmassewachstum und die Trockenmassepartitionierung auf Spross, Wurzeln, Blatt und Kolben, wurden diverse Parameter (nach-)kalibriert. Hierzu dienten die Daten von Wienforth (2011), während die NEffMais- und die RootWayS-Daten zur unabhängigen Evaluation genutzt wurden. Genauere Angaben zu den Parametern geben Holzhauser et al. (under review). Die spezielle Witterungssituation in Wehen und Bad Hersfeld in 2022 wurden im Modell durch eine starke Reduktion des Bodenwasserdefizitfaktors und eine entsprechend niedrigere Trockenmassebildung wiedergegeben. Die modellierten Trockenmassen korrelieren über die Jahre und Standorte hinweg sehr eng mit den gemessenen Trockenmassen ( $R^2 = 0.95$ , Abbildung 41). Es ist demnach mit dem Modell nun möglich, die Silomaisertragsbildung standort- und jahresspezifisch abzubilden. Auch die Trockenmassezunahme von Spross und Kolben wird vom Modell sehr gut abgebildet ( $R^2$  in der Evaluation = 0.92 bzw. 0.83). Ausbaufähig ist hingegen noch die Modellierung des Blattwachstums ( $R^2 = 0.44$ ) und damit zusammenhängend auch der photosynthetisch aktiven Fläche ( $R^2$  Leaf Area Index in der Evaluation = 0.5). Der bisherige Ansatz die Bestandeshöhe über den GAI zu berechnen wurde durch einen Ansatz basierend auf der Gesamttrockenmasse ersetzt. Dieser liefert in der Evaluation ein  $R^2$  von 0.97.



**Abbildung 41 (links): Bodenwasserdefizitsfaktor ( $f_{SWDF}$ ) und (rechts) Zusammenhang von gemessener und modellierter Trockenmasse in der mittelfrühen Reifegruppe in den beiden Versuchsjahren an den drei Versuchsstandorten (dunkelrot = Hohenschulen/ sandiger Lehm, orange = Bad Hersfeld/ Sand, gelb = Wehnen/ sandiger Schluff). (erstellt von K. Holzhauser)**

#### **Arbeitspaket 5, Teil 2: Auf- und Überarbeitung des Prozessmodells im Hinblick auf die Ertragsbildung mit N-Mangel**

Wie bereits beschrieben, lag zu Beginn des Projektes an der CAU bereits ein Ansatz zur Modellierung der N-Aufnahme im Silomais bei N-Mangel vor. Bei diesem wird bei der Berechnung der aktuellen Lichtnutzungseffizienz aus der potentiellen Lichtnutzungseffizienz neben dem Bodenwasserdefizitfaktor auch ein N-Defizitfaktor, der NNI (*nitrogen nutrition index*), verwendet. Dieser berechnet sich aus dem Verhältnis von aktueller N-Konzentration der Silomaispflanze zum sogenannten  $N_{crit}$  (= Wert ab dem die N-Konzentration das Trockenmassewachstum nicht limitiert). Die aktuelle N-Konzentration berechnet sich aus dem Verhältnis von N-Verfügbarkeit aus dem Boden und N-Bedarf der Pflanze; ist die N-Verfügbarkeit geringer als der N-Bedarf der Pflanze sinkt die N-Konzentration der Pflanze unter  $N_{crit}$  und reduziert im nächsten Tagesschritt die Lichtnutzungseffizienz. Die N-Verfügbarkeit des Bodens wird über N-Pools im Boden, die N-Düngung, Verluste in Abhängigkeit von der Witterung, abzüglich der bisherigen N-Aufnahme durch die Pflanze, modelliert. Der N-Bedarf der Pflanzen berechnet sich aus ihrer N-Konzentration und dem Trockenmassenzuwachs.

Durch den Zusammenhang von Ertragsbildung und N-Aufnahme und die im letzten Abschnitt beschriebenen starken Überarbeitungen des zugrunde liegenden Ertragsbildungsmodells ist eine Evaluierung des bisherigen N-Aufnahmemodells unabdingbar. Zudem stellt sich die Frage, inwiefern durch die Weiterentwicklung des Modells die Abschätzung des N-Bedarfs verbessert werden kann, etwa durch eine Erweiterung der pflanzenspezifischen Betrachtung auf eine organspezifische Betrachtung oder die Einbindung der in AP3 identifizierten Standort- und Managementeffekte auf die N-Nettomineralisation. Durch die starke Verzögerung der Arbeiten am Modell ohne N-Stress und der Übergabe der N-Konzentrationsdaten aus AP1 konnte mit diesen Arbeiten erst mit starker Verzögerung (ab April 2024) begonnen werden und hätte ohne die Arbeit von Frau Holzhauser aus dem RootWayS-Projekt trotz der kostenneutralen Verlängerung bis Dezember 2024 nicht finalisiert werden können. Weitere Ausführungen zu den hier beschriebenen Arbeiten werden sich in ihrer Dissertations-Schrift nachlesen lassen und sollen noch in einem peer-reviewed Journal veröffentlicht werden. Die Auswertung basiert ausschließlich auf Daten von mittelfrühen Sorten. Die an der GAUG, noch basierend auf den in AP1 erhobenen laufenden Aktivitäten zur Sortenabhängigkeit des  $N_{crit}$  und der Allometrien könnten relativ schnell in das Modell aufgenommen werden um so auch die Prognose von Sorteneffekten auf die Ertragsbildung und N-Aufnahme zu prognostizieren.

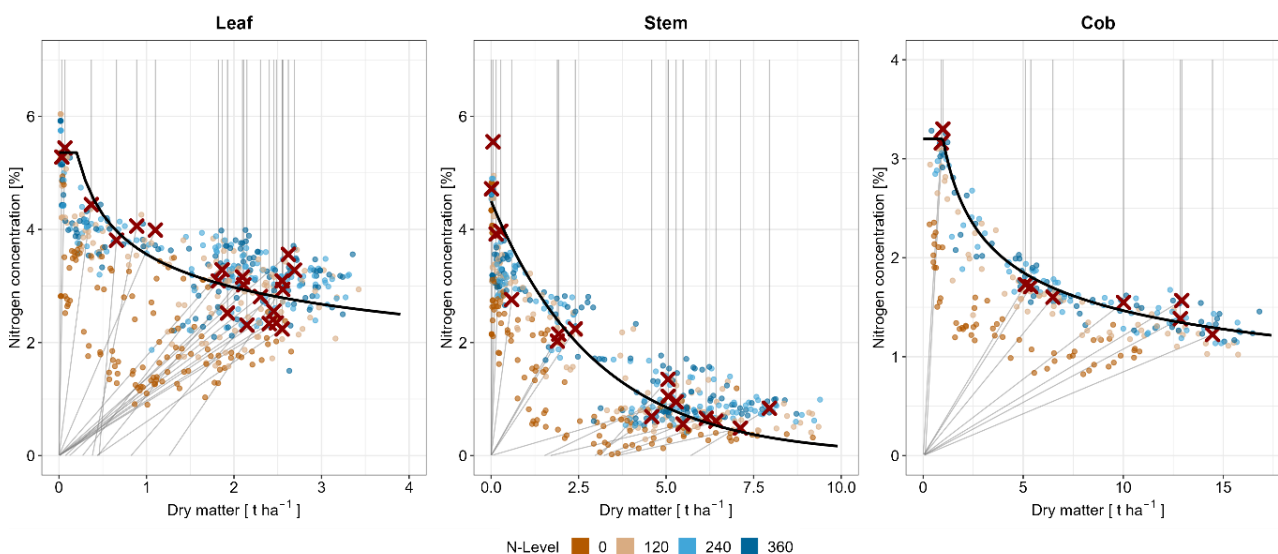
Die im Modell bislang implementierte Abhängigkeit des  $N_{crit}$  von der Trockenmasse nach Herrmann und Taube (2004) für die Silomais-Gesamtpflanze, wurde auf der Basis aller vorliegenden Daten (Kalibration: BiogasExpert-Daten, Evaluation: NEffMais-Daten) überprüft. Hierzu wurde entsprechend Justes (1994) mittels linear-plateau Funktionen für jeden Termin ein  $N_{crit}$  berechnet. Die Daten, bei denen die Funktion nicht konvergierte, wurden von der weiteren Betrachtung ausgeschlossen. Die N-Verdünnungskurve wird durch eine quadratische Funktion mit einem Plateau für Trockenmassewerte über einem kritischen

Trockenmassewert (=  $DM_{crit}$ ) wiedergegeben (Herrmann und Taube 2004; Plénet und Lemaire 1999) (Formel 14):

$$N_{conc} = \begin{cases} a & | DM < DM_{crit} \\ a \times DM^b & | DM \geq DM_{crit} \end{cases} \quad (14)$$

Wobei a die N-Konzentration für Trockenmassen unter  $N_{crit}$  ist und b die Abnahme der K-Konzentration mit Trockenmassezunahme darstellt. Es ergab sich auf Grundlage des Kalibrationsdatensatzes ein a von 4.89 bis zu einem  $DM_{crit}$  von  $0.52 \text{ t} \cdot \text{ha}^{-1}$ . Diese Koeffizienten unterscheiden sich zum Teil deutlich von denen von Plénet and Lemaire (1999) und Herrmann and Taube (2004) ( $3.4 \times DM^{-0.37}$  and  $3.4 \times DM^{-0.39}$ , mit einem  $DM_{crit}$  von  $1 \text{ t} \cdot \text{ha}^{-1}$ ). Mögliche Unterschiede hierfür könnte eine unterschiedliche Bearbeitungssoftware sein, oder auch eine im Zuge des Klimawandels unterschiedlich lange Vegetationsperiode (Yue et al. 2014).

In einem nächsten Schritt wurden organspezifische kritische N-Verdünnungskurven gefittet (Abbildung 42). Dabei ergaben sich aus den Daten über die Jahre sehr stabile  $N_{crit}$ -Verläufe für Gesamtpflanze, Stängel und Kolben. Der Zusammenhang für das Blatt streut hingegen innerhalb und zwischen den Jahren deutlich. Für die Blatt-Verdünnungskurve wurde eine quadratische Funktion gewählt, die mit einem Plateau bei 5.36 % startet. Für den Stängel wurde der beste Fit mit einer Exponentialfunktion erreicht, bei der das Plateau vernachlässigbar war (bei einem  $DM_{crit}$  von  $0.001 \text{ t} \cdot \text{ha}^{-1}$ ) (Tabelle 20).



**Abbildung 42: Für die Gesamtpflanze und Organ-spezifisch (Blatt, Stängel, Kolben) berechnete  $N_{crit}$ -Werte. (erstellt von K. Holzhauser)**

**Tabelle 20: N-Verdünnungskurven für die Gesamtpflanze und für die Pflanzenorgane (Blatt, Stängel, Kolben) mit einem Trockenmasse (DM)-Schwellenwert  $DM_{crit}$  unter dem die Funktion konstant bleibt.**

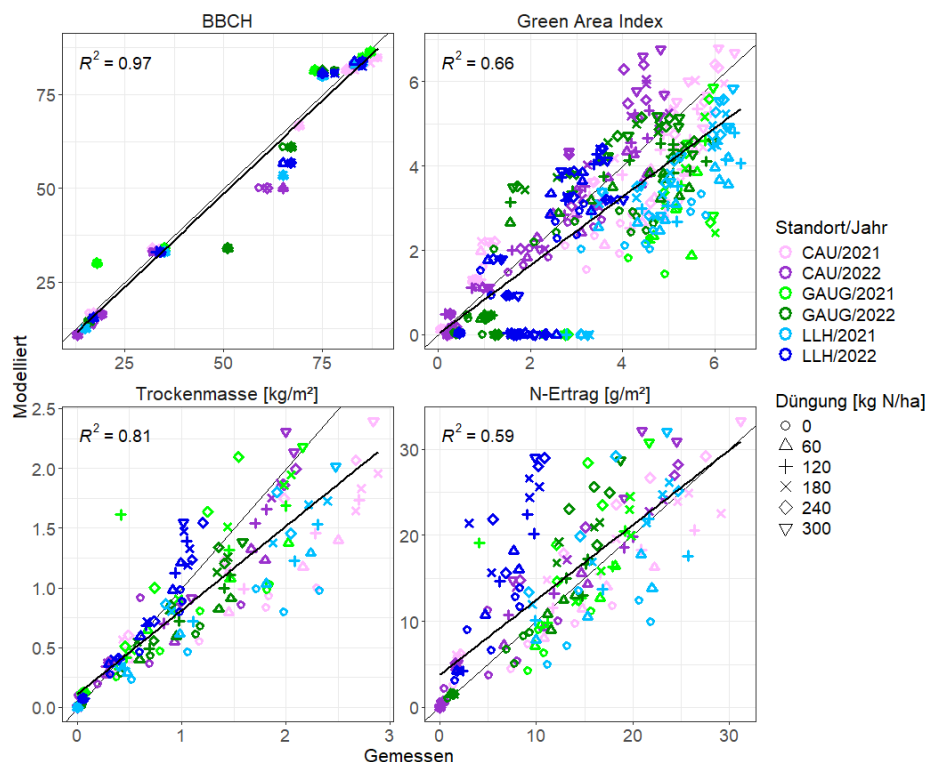
Organ	$DM_{crit} [\text{t} \cdot \text{ha}^{-1}]$	$DM < DM_{crit}$	$DM \geq DM_{crit}$	Anzahl der gefitteten $N_{crit}$ (= Anzahl der Termine)
Gesamtpflanze	0.52	4.89	$4.89 \times DM^{-0.37}$	19
Blatt	0.21	5.36	$5.36 \times DM^{-0.26}$	21
Stängel	0.001	4.50	$4.50 \times e^{-0.33 \times DM}$	17
Kolben	0.98	3.20	$3.20 \times DM^{-0.34}$	9

Da der in HUME-basierte Ansatz der Abbildung von N- und Wasser-Stress auf der Reduktion der potentiellen Lichtnutzungseffizienz basiert, und diese vor allem von der photosynthetisch aktive Blattfläche geprägt wird, wurde im Anschluss der tägliche NNI als Quotient zwischen der berechneten Blatt-N-Konzentration und dem Blatt- $N_{crit}$  bestimmt. Es zeigte sich nur eine geringe Variation des NNIs zwischen den gedüngten Varianten, und war nur am Ende der Saison deutlich unter 1. Im Gegenteil dazu war der NNI der ungedüngten Varianten zu Beginn der Saison am höchsten und nahm über die Saison ab, bis auf 0.4 in 2007 und in 2008 auf 0.3.

Neben der Umstellung von der Betrachtung der Gesamtpflanzen-N-Aufnahme auf die N-Aufnahme der einzelnen Organe bedurfte es der Nachkalibrierung mehrerer Faktoren. So wurde auf der Basis der Ertragsdaten die potentielle Lichtnutzungseffizienz (LUE) gegenüber dem Modell ohne N-Stress auf  $4.6 \text{ g} \cdot \text{MJ}^{-1}$  angepasst. In den bereits bestehenden Modellkomponenten, die über die N-Verfügbarkeit im System

bestimmen (unter anderem benutzt von Ratjen und Kage (2015) für Winterweizen), wurden zwei Änderungen vorgenommen: Basierend auf allen Daten wurde ein Faktor gefittet, der auf die Stärke der N-Nachlieferung aus dem Boden einwirkt ( $k_{\text{sombiom}} = 0.0003 \text{ 1} \cdot \text{d}^{-1}$ ). Dieser Faktor wurde über die Standorte und Jahre als konstant angenommen. Zudem wurden die Erkenntnisse zur negativen Rückkopplung der N-Düngung auf die N-Nachlieferung durch einen Faktor implementiert, der Zunahme der Gesamt-N-Verfügbarkeit im System bei zunehmender Düngung unterproportional steigen lässt ( $f_{\text{recovery}} = 0.8$ ) (siehe Abschnitt zu AP3). Keine Änderungen erfolgten in den Komponenten für Phänologie und Wasserhaushalt.

Das resultierende Modell erzielt mit einem  $R^2$  von 0.81 eine hohe Erklärungsgüte für das Trockenmassewachstum in den beiden Jahren an den drei Standorten (Abbildung 43). Allerdings werden in 2021 hohe erfasste Trockenmassen am Standort der CAU und des LLHs deutlich unterschätzt. Dies lässt sich auf eine Unterschätzung des Green Area Index zurückführen (Abbildung 43). Neben der tendenziellen Unterschätzung hoher Green Area Index-Werte kam es in einzelnen Fällen zu Problemen bei der Vorhersage sehr kleine GAI-Werte zu modellieren. Obwohl das Trockenjahr 2022 beim LLH sowohl in seiner Phänologie, als auch in der Ausbildung des Green Area Index und dem Trockenmassewachstum gut abgebildet wird, wird der N-Ertrag deutlich überschätzt (Abbildung 45). Dies führt mit 0.59 zu einem relativ geringen  $R^2$  für diesen Bestandesparameter, ohne Berücksichtigung dieser Daten liegt das  $R^2$  bei 0.75.



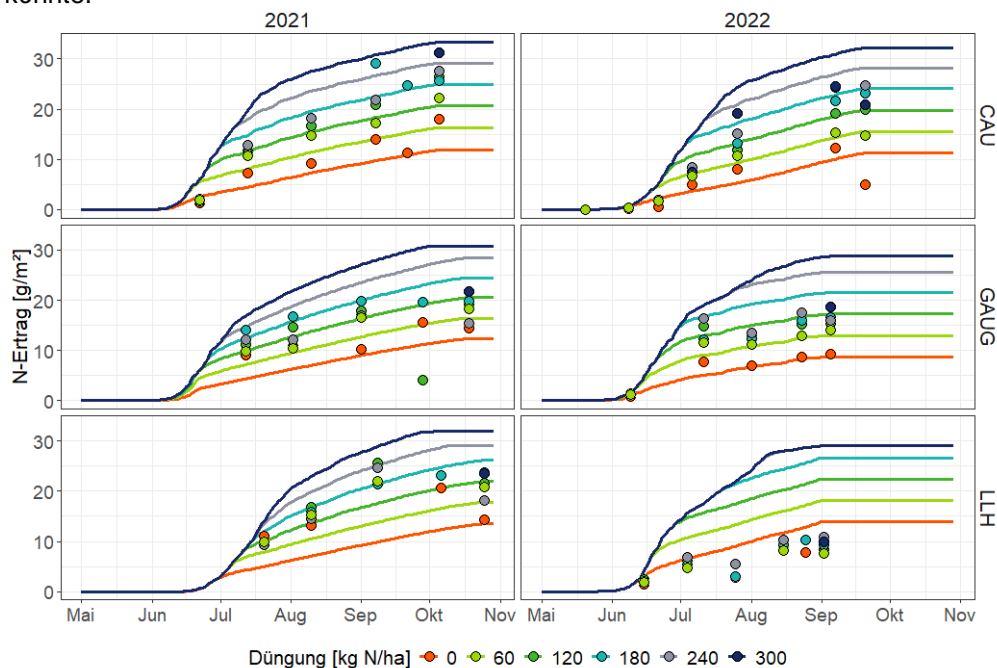
**Abbildung 43: Korrelation von über die Saison 2021 und 2022 an den drei Standorten erfassten und modellierten Bestandesparametern. Der Green Area Index wurde UAV-basiert erfasst (siehe AP2).**

In Abbildung 44 ist erkennbar, dass das Modell in 2022 einen sehr ähnlichen N-Ertrag wie in 2021 prognostiziert, sowohl in seinem Niveau wie auch in der Variabilität zwischen den verschiedenen N-Stufen. Die gemessenen N-Aufnahmen sind jedoch ab Mitte Juni deutlich niedriger und differenzieren kaum zwischen den Düngewarianten. Selbst die N-Aufnahme in der 300 N-Variante ist zu jedem Messtermin unter der modellierten der 0 N-Variante. Offenbar ist das Modell zwar in der Lage, die Reaktion der Blattflächen- und Ertragsbildung auf Trockenstress abzubilden, jedoch nicht die Einschränkungen der N-Aufnahme der Pflanze aus dem Boden, die sich durch eine eingeschränkte Wasserverfügbarkeit ergeben.

Auch in 2021 beim LLH wird die Dynamik der N-Aufnahme nicht optimal beschrieben; die N-Aufnahme bis Oktober wird in allen N-Varianten unterschätzt und die höheren N-Stufen werden deutlich überschätzt. Auch an den anderen beiden Standorten wird die N-Aufnahme der hoch gedüngten Varianten unterschätzt und die frühe N-Aufnahme nicht optimal abgebildet. Dies deutet darauf hin, dass die N-Verfügbarkeit im Boden, die sich aus der Summe von N-Düngung und N-Nachlieferung ergibt, nicht korrekt in ihrer Höhe und Dynamik ist.

Die hierfür zuständige Modellkomponente ist ein stark vereinfachter Ansatz, der die N-Freisetzung aus der organischen Bodensubstanz und den Ernterückständen mit nur 4 Kohlenstoffpools und den daraus abgeleiteten N-Flüssen prognostiziert. Auch ist die Annahme eines über die Standorte hinweg konstanten  $k_{\text{sombiom}}$  mit hoher Sicherheit nicht zutreffend. Weiterhin liegt die Vermutung nahe, dass die gemeinsamen Auswirkungen einer im Sommer eingeschränkten Bodenfeuchte und höhere Bodentemperaturen (Cassman und Munns 1980) nicht angemessen wiedergegeben werden.

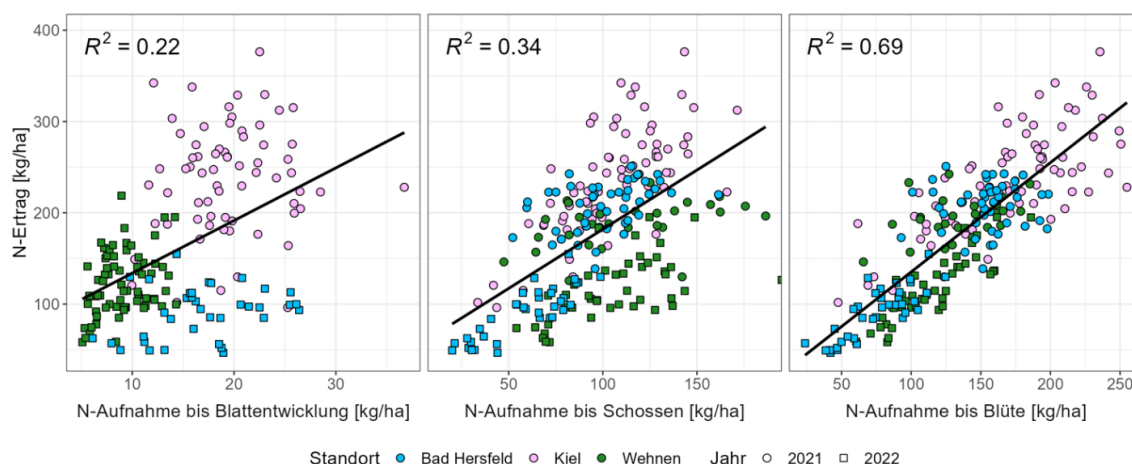
Die Abschnitt AP4 gezeigten Ansätze lassen es jedoch denkbar erscheinen, dass eine standortspezifische Parametrisierung der Modellkomponente auf der Grundlage von NIRS-Messungen die Prognosegüte verbessern könnte.



**Abbildung 44: Modellierte (Linie) und gemessene (Punkte) N-Aufnahme in den Bestand über die Saison 2021 und 2022 an den drei Standorten. Farben zeigen die unterschiedliche mineralische Düngung.**

#### Nutzung des Modells zur Evaluierung der Prognose des Ertrags und des N-Düngebedarfs zum 8-Blattstadium

In einem ersten Schritt wurde evaluiert, wie eng der empirische Zusammenhang der N-Aufnahme bis zur Blattformung mit dem finalen N-Ertrag ist (Abbildung 45). Auf Grund der in 2022 am LLH deutlich anderen Versuchsbedingungen ist die Korrelation der gemessenen frühen N-Aufnahme mit dem finalen N-Ertrag gering. Erst zur Blüte können die bis zu dem Zeitpunkt stattfindende N-Aufnahme mehr als 50 % der Variabilität im N-Ertrag erklärt werden (Abbildung 45). Demnach ist eine Abschätzung des Ertrags bzw. des N-Düngebedarfs mittels einer empirischen Regression auf Grund der großen Variabilität zwischen den Jahren nicht empfehlenswert.



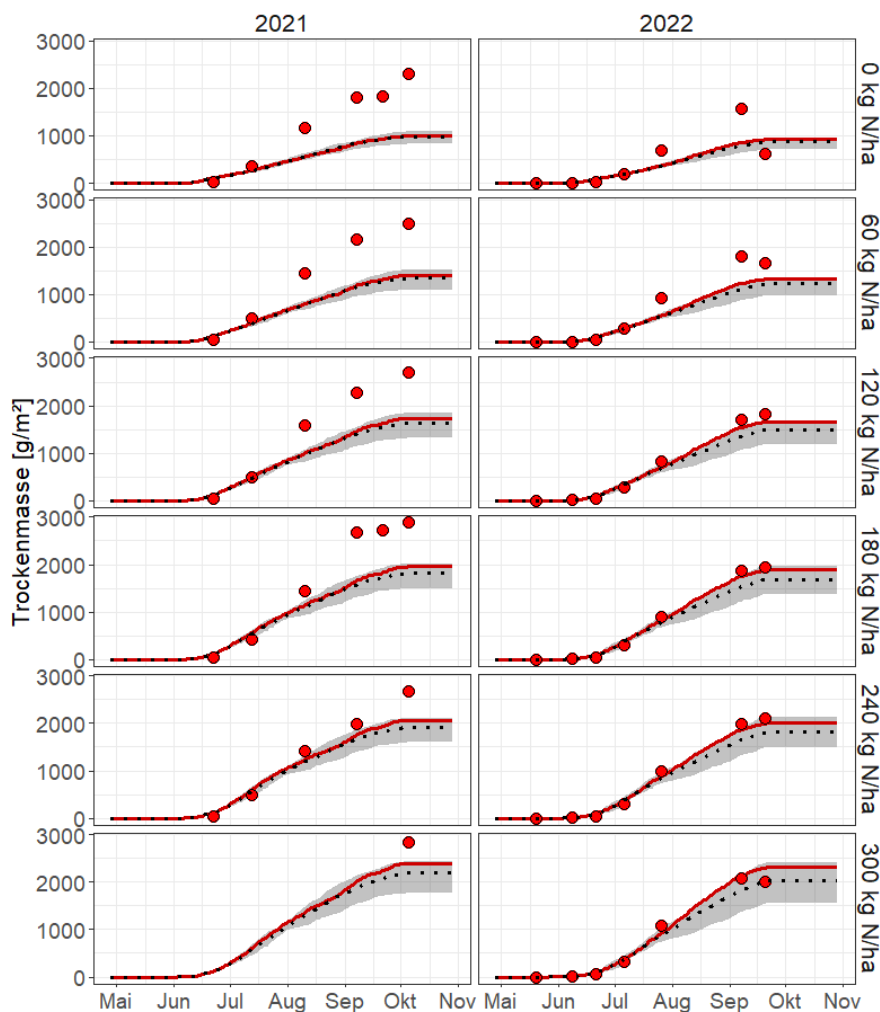
**Abbildung 45: Korrelation der N-Aufnahme in den Pflanzenbestand in der frühen Saison mit dem finalen N-Ertrag (Standort des LLH = Bad Hersfeld, der CAU = Kiel, der GAUG = Wehen). Auf Grund von Unterschieden in der zeitlichen Gestaltung der Probenahmetermine und von Problemen bei der Laboranalyse sind nicht von jeder Beprobung an jedem Standort Daten verfügbar.**

Momentan werden HUME-basierte Szenariorechnungen durch eine Ergänzung der bis zu dem Messzeitpunkt erhobenen Witterungsdaten durch die Witterungsdaten der vorherigen Jahre durchgeführt. Aus dem Ensemble der sich ergebenden Prognosen kann dann im Anschluss ein Mittelwert als das am wahrscheinlichsten eintretende Szenario ausgewählt und mit dessen Ertragsprognosen weitergearbeitet werden. Für die Prognose des N-Düngebedarfs können Ertragsprognosen mit unterschiedlichen N-Düngungshöhen erstellt und daraus eine Ertrags-Responsekurve berechnet werden. Da die Witterungsbedingungen in den Versuchsjahren am Standort der GAUG und insbesondere des LLHs äußerst ungewöhnlich waren, ist auch bei einer optimalen Modell-basierten Abbildung der N-Aufnahme bis zur Blattformung unter der Annahme

eines für den Standort im Mittel der Jahre wahrscheinlichen Wetters keine hohe Korrelation mit den finalen N-Erträgen bzw. keine gute Grundlage zur Prognose des N-Düngebedarf zu erwarten. Im Zuge des Klimawandels wird in Deutschland mit einer erhöhten Variabilität der Niederschläge gerechnet. Derartige Bedingungen im Silomaisanbau werden sich demnach in den nächsten Jahren tendenziell häufiger ergeben. Dies wird die Landwirtschaft vor große Herausforderungen stellen. Gleichzeitig wird jedoch auch der Datensatz über derartige Witterungslagen wachsen, so dass die Prognose des Weiteren Saisonverlaufs ggf. genauer werden wird. Hiervon könnte eine auf prozess-basierte Modellierung basierende Ertragsmodellierung profitieren.

Die Genauigkeit einer HUME-Maize-basierte Ertragsprognose zum 8-Blattstadium unter für einen Standort typischen Witterungsbedingungen, wurde daher nur auf Grundlage des Datensatzes des CAU-Standes geprüft. Das 8-Blattstadium wurde in diesem Versuch am 1. Juli 2021 bzw. am 21. Juni 2022 bonitiert. Die Szenarien basieren auf der Witterung der dem Versuchsjahr vorangegangenen 10 Jahre. Basierend auf den Ergebnissen von Arbeitspaket 3 wurde eine quadratisch-plateau Funktion zur Abbildung der Ertragszunahme bei steigender N-Düngung genutzt.  $N_{max}$  entspricht dem Punkt, ab dem das Plateau der Funktion erreicht ist, und kann als mögliche Düngeempfehlung diskutiert werden. Dabei entspricht  $N_{max}$  der gemessenen Erträge dem ex-post ermitteltem Düngeoptimum und das Ziel wäre ein möglichst nah daran liegendes  $N_{max}$  der modellierten Erträge.

Die Szenariorechnungen zeigen eine heterogene Prognosegüte in den N-Stufen und Jahren (Abbildung 46). Das Modell prognostiziert im Mittel der Szenarien eine deutlich niedrigere Trockenmassebildung als auf der Basis der tatsächlichen Witterungsdaten und im Vergleich mit den destruktiven Messungen. Hierbei ist die Modellprognose mit den tatsächlichen Witterungsdaten für das Versuchsjahr 2022 sehr nah an den destruktiven Messungen. In 2021 hingegen liegen sämtliche Modellprognosen deutlich unter den gemessenen Werten. In beiden Jahren sind die Trockenmasseprognosen genauer in den höher gedüngten Varianten. So wird in 2021 die Trockenmassebildung auf den ungedüngten Parzellen um circa die Hälfte unterschätzt, in der betriebsüblich gedüngten Variante ( $240 \text{ kg N} \cdot \text{ha}^{-1}$ ) um etwa ein Fünftel. Offenbar unterschätzt das Modell die N-Menge, die aus dem Boden zur Verfügung gestellt wird. Durch die höhere Sensitivität der Ertragsbildung auf unterschiedliche N-Mengen im niedrigeren N-Bereich (quadratisch-plateau Funktion, siehe Arbeitspaket 3) ist das Problem in den weniger gedüngten Varianten deutlicher.

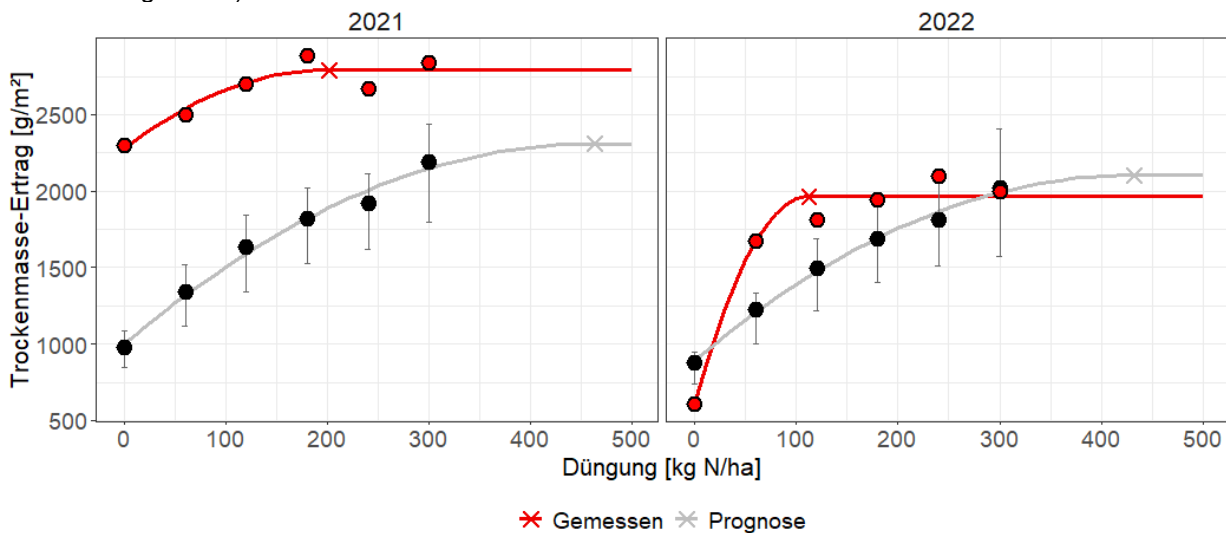


**Abbildung 46: Szenarienrechnung für die Trockenmasseentwicklung am Versuchsstandort der CAU in den beiden Versuchsjahren 2021 und 2022 (rote Punkte: destruktive Messungen, rote Linie: Modellrechnung mit vollständigem Wetter aus dem entsprechenden Versuchsjahr, graue Fläche:**

## Range der Trockenmasseprognosen auf der Basis der Witterungsdaten der 10 vorherigen Jahre ab dem 8-Blattstadium, schwarze Linie: Mittel dieser Prognosen).

Auf der Basis der gemessenen und der Mittelwerte der Witterungsszenarien-basiert modellierten Erträge zum Erntetermin wurden quadratisch-plateau Responsekurven gefittet und der entsprechende  $N_{max}$  berechnet (Abbildung 47). Die Modell-basierten Responsekurven gaben weder den gemessenen Funktionsverlauf, noch das jahresspezifische Niveau der Ertragsreaktion korrekt wieder. Durch die starke Unterschätzung der Erträge der wenig gedüngten Varianten verläuft die Responsefunktion zu steil und sättigt daher erst deutlich zu spät ab. Dies wird mit hoher Wahrscheinlichkeit mit der unzuverlässigen Prognose der Stickstoffnachlieferung zusammenhängen.

Die zum Zeitpunkt des 8-Blattstadiums prognostizierten  $N_{max}$ -Werte liegen damit in beiden Jahren deutlich (2021: +261 kg N·ha<sup>-1</sup>, 2022: +321 kg N·ha<sup>-1</sup>) über den ex-post berechenbaren Werten (2021: +202 kg N·ha<sup>-1</sup>, 2022: 112 kg N·ha<sup>-1</sup>).



**Abbildung 47: Trockenmassereaktion auf die N-Düngung am Versuchsstandort der CAU in den beiden Versuchsjahren 2021 und 2022 (rote Punkte: destruktive Messungen, schwarze Punkte: Mittelwert der Modell-basierte Prognosen, Linien: gefittete quadratisch-plateau (qp) Responsefunktion, Kreuze: Bruchpunkt der qp-Funktion ( $N_{max}$ )).**

Durch den Modellfehler ist zum Projektende keine Beurteilung der Auswirkungen des zum 8-Blattstadium von Mais noch unbekanntem weiteren Witterungsverlaufs möglich. Der größte Weiterentwicklungsbedarf wird in der Schätzung der N-Nachlieferung durch die Bodenkomponente des HUME-Modells gesehen. Für eine Verbesserung der Prognosegüte im Hinblick auf den jahres- und standortspezifischen Stickstoffbedarfs ist es notwendig, die Prognose der Nachlieferungs-Dynamik zu verbessern. Hierfür können die Daten aus Arbeitspaket 4 eine wichtige Rolle spielen. Ein Ansatz bestünde z.B. darin, für eine größere Anzahl an Standorten eine standortspezifische Parametrisierung dieses oder eines noch weiter vereinfachten Mineralisationsmodells vorzunehmen und die geschätzten Parameter für z.B. Poolgrößen und Umsatzparameter mit NIRS-Analysen zu korrelieren.

## Literaturverzeichnis

- Adee, Eric; Roozeboom, Kraig; Balboa, Guillermo R.; Schlegel, Alan; Ciampitti, Ignacio A. (2016): Drought-Tolerant Corn Hybrids Yield More in Drought-Stressed Environments with No Penalty in Non-stressed Environments. In: *Front. Plant Sci.* 7, S. 1534. DOI: 10.3389/fpls.2016.01534.
- Ad-hoc-AG Boden (2005): *Bodenkundliche Kartieranleitung*. 5. Auflage. Stuttgart.
- Agostini, Lucilla; Bünemann, Else K.; Jakobsen, Camilla; Salo, Tapio; Wester-Larsen, Lærke; Symanczik, Sarah (2024): *Prediction of Nitrogen Mineralization from Novel Bio-Based Fertilizers Using Chemical Extractions*: Elsevier BV.
- Agricultural Chamber Lower Saxony (2024): *Sortenempfehlungen und LSV-Ergebnisse Silomais mittelspätes Sortiment*. Online verfügbar unter [https://www.lwk-niedersachsen.de/lwk/news/42249\\_Sortenempfehlungen\\_und\\_LSV-Ergebnisse\\_Silomais\\_mittelspaetes\\_Sortiment](https://www.lwk-niedersachsen.de/lwk/news/42249_Sortenempfehlungen_und_LSV-Ergebnisse_Silomais_mittelspaetes_Sortiment).
- Akaike, Hirotugu (2011): Akaike's Information Criterion. In: *International Encyclopedia of Statistical Science*, S. 25. DOI: 10.1007/978-3-642-04898-2\_110.
- Alam, S. K.; Li, P.; Rahman, M.; Fida, M.; Elumalai, V. (2025): Alam, SM Khorshed, et al. "Key factors affecting groundwater nitrate levels in the Yinchuan Region, Northwest China: Research using the eXtreme Gradient Boosting (XGBoost) model with the SHapley Additive exPlanations (SHAP) method. In: *Environmental*

- Pollution* (364). Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/S0269749124020530>.
- Arriola, K. G.; Kim, S. C.; Huisden, C. M.; Adesogan, A. T. (2012): Stay-green ranking and maturity of corn hybrids: 1. Effects on dry matter yield, nutritional value, fermentation characteristics, and aerobic stability of silage hybrids in Florida.
- Asgari, Najmeh; Ayoubi, Shamsollah; Demattê, Jose Alexandre Melo; Dotto, André Carnieletto (2020): Carbonates and organic matter in soils characterized by reflected energy from 350–25000 nm wavelength. In: *J. Mt. Sci.* 17 (7), S. 1636–1651. DOI: 10.1007/s11629-019-5789-9.
- Au, Jessie; Youngentob, Kara N.; Foley, William J.; Moore, Ben D.; Fearn, Tom (2020): Sample selection, calibration and validation of models developed from a large dataset of near infrared spectra of tree leaves. In: *Journal of Near Infrared Spectroscopy* 28 (4), S. 186–203. DOI: 10.1177/0967033520902536.
- Bai, Yu; Yang, Wei; Wang, Zhaoyang; Cao, Yongyan; Li, Minzan (2024): Improving the estimation accuracy of soil organic matter based on the fusion of near-infrared and Raman spectroscopy using the outer-product analysis. In: *Computers and Electronics in Agriculture* 219, S. 108760. DOI: 10.1016/j.compag.2024.108760.
- Bailly, Alexandre; Blanc, Corentin; Francis, Élie; Guillotin, Thierry; Jamal, Fadi; Wakim, Béchara; Roy, Pascal (2022): Effects of dataset size and interactions on the prediction performance of logistic regression and deep learning models. In: *Computer Methods and Programs in Biomedicine* 213, S. 106504. DOI: 10.1016/j.cmpb.2021.106504.
- Barbieri, Pablo A.; Echeverría, Hernán E.; Saínz Rozas, Hernán R.; Andrade, Fernando H. (2008): Nitrogen Use Efficiency in Maize as Affected by Nitrogen Availability and Row Spacing. In: *Agronomy Journal* 100 (4), S. 1094–1100. DOI: 10.2134/agronj2006.0057.
- Barea-Sepúlveda, Marta; Ferreiro-González, Marta; Calle, José Luis P.; Barbero, Gerardo F.; Ayuso, Jesús; Palma, Miguel (2022): Comparison of different processing approaches by SVM and RF on HS-MS eNose and NIR Spectrometry data for the discrimination of gasoline samples. In: *Microchemical Journal* 172, S. 106893. DOI: 10.1016/j.microc.2021.106893.
- Baty, Florent; Delignette-Muller, Marie-Laure; Siberchicot, Aurelie (2024): nlstools: Tools for Nonlinear Regression Analysis. Online verfügbar unter <https://cran.r-project.org/web/packages/nlstools/index.html>, zuletzt geprüft am 07.01.2025.
- Bauer, Eric; Kohavi, Ron (1999): An Empirical Comparison of Voting Classification Algorithms: Bagging, Boosting, and Variants. In: *Machine Learning* 36 (1/2), S. 105–139. DOI: 10.1023/A:1007515423169.
- Bayerische Landesanstalt für Landwirtschaft (LfL) (2023): Landessortenversuche und Sortenberatung Silomais. Online verfügbar unter <https://www.lfl.bayern.de/ipz/mais/021680/index.php>, zuletzt geprüft am 28.06.2024.
- Benbi, D.; Richter, J. (2002): A critical review of some approaches to modelling nitrogen mineralization. In: *Biol Fertil Soils* 35 (3), S. 168–183. DOI: 10.1007/s00374-002-0456-6.
- Bignon, J. (1990): Agrométéorologie et physiologie du maïs grain dans la communauté Européenne.
- Birch, C. J.; Vos, J.; van der Putten, P.E.L. (2003): Plant development and leaf area production in contrasting cultivars of maize grown in a cool temperate environment in the field. In: *European Journal of Agronomy* 19 (2), S. 173–188. DOI: 10.1016/S1161-0301(02)00034-5.
- Bonde, T. A.; Rosswall, T. (1987): Seasonal Variation of Potentially Mineralizable Nitrogen in Four Cropping Systems. In: *SSSAJ* 51 (6), S. 1508–1514. DOI: 10.2136/sssaj1987.03615995005100060019x.
- Borken, W.; Matzner, E. (2009): Reappraisal of drying and wetting effects on C and N mineralization and fluxes in soils. In: *Global Change Biology* 15 (4), S. 808–824. DOI: 10.1111/j.1365-2486.2008.01681.x.
- Brauer-Siebrecht, Wiebke; Jacobs, Anna; Christen, Olaf; Götze, Philipp; Koch, Heinz-Josef; Rücknagel, Jan; Märkländer, Bernward (2016): Silage Maize and Sugar Beet for Biogas Production in Rotations and Continuous Cultivation: Dry Matter and Estimated Methane Yield. In: *Agronomy* 6 (1), S. 2. DOI: 10.3390/agronomy6010002.
- Breiman, L. (2001): Random Forests. Vol. 45.
- Breiman, Leo; Friedman, Jerome H.; Olshen, Richard A.; Stone, Charles J. (2017): Classification And Regression Trees: Routledge. Online verfügbar unter <https://www.taylorfrancis.com/books/mono/10.1201/9781315139470/classification-regression-trees-leo-breiman-jerome-friedman-olshen-charles-stone>.
- Bruun, Sander; Luxhøi, Jesper; Magid, Jakob; Neergaard, Andreas de; Jensen, Lars S. (2006): A nitrogen mineralization model based on relationships for gross mineralization and immobilization. In: *Soil Biology and Biochemistry* 38 (9), S. 2712–2721. DOI: 10.1016/j.soilbio.2006.04.023.
- Bukowiecki, J.; Holzhauser, K.; Kage, H.; Herrmann, A.; Komainda, M. (2023): Stickstoffdynamik im Mais mithilfe von Drohnen besser verstehen. In: *Mais* (50, Heft 3).

- Bukowiecki, J.; Rose, T.; Holzhauser, K.; Rothardt, S.; Rose, M.; Komainda, M. et al. (2024): UAV-based canopy monitoring: calibration of a multispectral sensor for green area index and nitrogen uptake across several crops. In: *Precis. Agric.*, S. 1–25. DOI: 10.1007/s11119-024-10123-2.
- Bukowiecki, J.; Rose, T., Kage, H. (2024): Assessment of the impact of accurate green area index, water regime and harvest index on site-specific wheat yield estimation. In: *Computers and Electronics in Agriculture*.
- Bukowiecki, J.; Ullrich, L.; Komainda, M.; Herrmann, A.; Kage, H.; Kühling, I. (Xa): A closer look at European fertilizer legislations for silage maize: Part I – inaccurate account of net N mineralization.
- Bukowiecki, J.; Ullrich, L.; Komainda, M.; Herrmann, A.; Kage, H.; Kühling, I. (Xb): A closer look at European fertilizer legislations for silage maize: Part II - overestimation of economically optimal N rates.
- Buljovic, Zaklina; Engels, Christof (2001): Nitrate uptake ability by maize roots during and after drought stress. In: *Plant and Soil* 229 (1), S. 125–135. DOI: 10.1023/A:1004879201623.
- Carpenter-Boggs, L.; Pikul, J. L.; Vigil, M. F.; Riedell, W. E. (2000): Soil Nitrogen Mineralization Influenced by Crop Rotation and Nitrogen Fertilization. In: *SSSAJ* 64 (6), S. 2038–2045. DOI: 10.2136/sssaj2000.6462038x.
- Cassman, K. G.; Munns, D. N. (1980): Nitrogen Mineralization as Affected by Soil Moisture, Temperature, and Depth. In: *SSSAJ* 44 (6), S. 1233–1237. DOI: 10.2136/sssaj1980.03615995004400060020x.
- Chen, Tianqi; Guestrin, Carlos (2016): XGBoost. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA. New York, NY, USA: ACM, S. 785–794.
- Chen, Xinping; Zhang, Fusuo; Cui, Zhenling; Li, Junliang; Ye, Youliang; Yang, Zhiping (2010): Critical Grain and Stover Nitrogen Concentrations at Harvest for Summer Maize Production in China. In: *Agronomy Journal* 102 (1), S. 289–295. DOI: 10.2134/agronj2009.0226.
- Chen, Z.; Leffler, A. J. (2024): Soil basal respiration and nitrogen mineralization from C3 and C4 grass dominated plant communities respond differently to temperature and soil water variation. In: *Journal of Arid Environments* (224). Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/S0140196324001150>.
- Ciampitti, Ignacio A.; Fernandez, Javier; Tamagno, Santiago; Zhao, Ben; Lemaire, Gilles; Makowski, David (2021a): Does the critical N dilution curve for maize crop vary across genotype x environment x management scenarios? - a Bayesian analysis. In: *European Journal of Agronomy* 123, S. 126202. DOI: 10.1016/j.eja.2020.126202.
- Ciampitti, Ignacio A.; Makowski, David; Fernandez, Javier; Lacasa, Josefina; Lemaire, Gilles (2021b): Does water availability affect the critical N dilution curves in crops? A case study for maize, wheat, and tall fescue crops. In: *Field Crops Research* 273, S. 108301. DOI: 10.1016/j.fcr.2021.108301.
- Ciampitti, Ignacio A.; Murrell, Scott T.; Camberato, J. J.; Tuinstra, Mitch; Xia, Yanbing; Friedemann, Peter; Vyn, Tony J. (2013): Physiological Dynamics of Maize Nitrogen Uptake and Partitioning in Response to Plant Density and N Stress Factors: I. Vegetative Phase. In: *Crop Science* 53 (5), S. 2105–2119. DOI: 10.2135/cropsci2013.01.0040.
- Ciampitti, Ignacio A.; Vyn, Tony J. (2012): Physiological perspectives of changes over time in maize yield dependency on nitrogen uptake and associated nitrogen efficiencies: A review. In: *Field Crops Research* 133, S. 48–67. DOI: 10.1016/j.fcr.2012.03.008.
- Colopietro, Daniel J.; Pachon, Julio; Bacon, Allan (2025): Investigating soil properties influencing the depth and degree of leaching in Florida soils using a random forest modeling approach. In: *Geoderma Regional* 40, e00916. DOI: 10.1016/j.geodrs.2025.e00916.
- Cortes, Corinna; Vapnik, Vladimir (1995): Support-vector networks. In: *Mach Learn* 20 (3), S. 273–297. DOI: 10.1007/BF00994018.
- Cougnon, M.; van den Berge, K.; D'Hose, T.; Clement, L.; Reheul, D. (2018): Effect of management and age of ploughed out grass-clover on forage maize yield and residual soil nitrogen. In: *J. Agric. Sci.* 156 (6), S. 748–757. DOI: 10.1017/s0021859618000631.
- Cui, Chenhao; Fearn, Tom (2017): Comparison of partial least squares regression, least squares support vector machines, and Gaussian process regression for a near infrared calibration. In: *Journal of Near Infrared Spectroscopy* 25 (1), S. 5–14. DOI: 10.1177/0967033516678515.
- Cui, Zhenling; Wang, Guiliang; Yue, Shanchao; Wu, Liang; Zhang, Weifeng; Zhang, Fusuo; Chen, Xinping (2014): Closing the N-use efficiency gap to achieve food and environmental security. In: *Environmental science & technology* 48 (10), S. 5780–5787. DOI: 10.1021/es5007127.
- Curtin, Denis; Campbell, C. A.; Jalil, Abdul (1998): Effects of acidity on mineralization: pH-dependence of organic matter mineralization in weakly acidic soils. In: *Soil Biology and Biochemistry* 30 (1), S. 57–64. DOI: 10.1016/S0038-0717(97)00094-1.
- Degaspari, Iracema Alves Manoel; Soares, Johnny Rodrigues; Montezano, Zaqueu Fernando; Del Grosso, Stephen J.; Vitti, André Cesar; Rossetto, Raffaella; Cantarella, Heitor (2020): Nitrogen sources and

- application rates affect emissions of N<sub>2</sub>O and NH<sub>3</sub> in sugarcane. In: *Fertilizer Research* 116 (3), S. 329–344. DOI: 10.1007/s10705-019-10045-w.
- Degener, Jan F.; Kappas, Martin (2015): Differences in biomass yield development of early, medium, and late maize varieties during the 21st century in Northern Germany. In: *Environ Sci Eur* 27 (1), S. 1–13. DOI: 10.1186/s12302-015-0042-9.
- Dessureault-Rompré, Jacynthe; Zebarth, Bernie J.; Burton, David L.; Georgallas, Alex (2015): Predicting soil nitrogen supply from soil properties. In: *Can. J. Soil. Sci.* 95 (1), S. 63–75. DOI: 10.4141/cjss-2014-057.
- Deutsches Maiskomitee e.V. (DMK) (2024): Statistik: Maisanbau in Deutschland. Online verfügbar unter <https://www.maiskomitee.de/public/Fakten.aspx/Statistik/Deutschland/Maisanbau>, zuletzt geprüft am 27.06.2024.
- Devianti; Sufardi; Bulan, Ramayanty; Sitorus, Agustami (2022): Vis-NIR spectra combined with machine learning for predicting soil nutrients in cropland from Aceh Province, Indonesia. In: *Case Studies in Chemical and Environmental Engineering* 6, S. 100268. DOI: 10.1016/j.cscee.2022.100268.
- Devos, Olivier; Ruckebusch, Cyril; Durand, Alexandra; Duponchel, Ludovic; Huvenne, Jean-Pierre (2009): Support vector machines (SVM) in near infrared (NIR) spectroscopy: Focus on parameters optimization and model interpretation. In: *Chemometrics and Intelligent Laboratory Systems* 96 (1), S. 27–33. DOI: 10.1016/j.chemolab.2008.11.005.
- Dhaliwal, Sukhpreet Singh; Nahid, Abdullah-Al; Abbas, Robert (2018): Effective Intrusion Detection System Using XGBoost. In: *Information* 9 (7), S. 149. DOI: 10.3390/info9070149.
- Du, Xinrong; Chen, Huazhou; Xie, Jun; Li, Linghui; Cai, Ken; Meng, Fangxiu (2025): Quantitative analysis of soil potassium by near-infrared (NIR) spectroscopy combined with a three-step progressive hybrid variable selection strategy. In: *Spectrochimica acta. Part A, Molecular and biomolecular spectroscopy* 324, S. 124998. DOI: 10.1016/j.saa.2024.124998.
- Duru, M.; Lemaire, G.; Cruz, P. (Hg.) (1997): Diagnosis of the nitrogen status in crops. Grasslands. Berlin Heidelberg: Springer-Verlag.
- DüV (2017): Düngeverordnung vom 26. Mai 2017 (BGBl. I S. 1305), die zuletzt durch Artikel 97 des Gesetzes vom 10. August 2021 (BGBl. I S. 3436) geändert worden ist.
- Ehlers, Wilfried; Goss, Michael (2016): Water dynamics in plant production. 2nd edition. Wallingford, Boston: CABI.
- Eiler, T.; Bauer, A. (2014): N-Düngestrategien im Maisanbau. Versuche zur grundwasserschutzorientierten Landbewirtschaftung im Rahmen der landesweiten Aufgaben gem. § 28 NWG. LK Niedersachsen, 2014. Online verfügbar unter not anymore online available.
- Engels, Thomas; Kuhlmann, Hermann (1993): Effect of the rate of N fertilizer on apparent net mineralization of N during and after cultivation of cereal and sugar beet crops. In: *J. Plant Nutrition & Soil* 156 (2), S. 149–154. DOI: 10.1002/jpln.19931560209.
- Ergon, Å.; Seddaiu, G.; Korhonen, P.; Virkajärvi, P.; Bellocchi, G.; Jørgensen, M. et al. (2018): How can forage production in Nordic and Mediterranean Europe adapt to the challenges and opportunities arising from climate change? In: *European Journal of Agronomy* 92, S. 97–106. DOI: 10.1016/j.eja.2017.09.016.
- European Commission (2023): Green maize by area, production and humidity - Data Europa EU. Online verfügbar unter <https://data.europa.eu/data/datasets/7gxelzhfclif0wcrbpzfog?locale=en>, updated on 12/7/2023, zuletzt geprüft am 01.03.2024.
- European Parliament; Council of European Union Council (1991): Directive 91/676/EEC of 12 December 1991 concerning the protection of waters against pollution caused by nitrates from agricultural sources. In: *Off. J. Eur. Union*, L 375, 1–8.
- Fidêncio, Paulo H.; Poppi, Ronei J.; Andrade, João Carlos de (2002): Determination of organic matter in soils using radial basis function networks and near infrared spectroscopy. In: *Analytica Chimica Acta* 453 (1), S. 125–134. DOI: 10.1016/s0003-2670(01)01506-9.
- Filya, I. (2004): Nutritive value and aerobic stability of whole crop maize silage harvested at four stages of maturity. In: *Animal Feed Science and Technology* 116 (1-2), S. 141–150. DOI: 10.1016/j.anifeedsci.2004.06.003.
- Finke, C.; Möller, K.; Schlink, S.; Gerowitt, B.; Isselstein, J. (1999): The environmental impact of maize cultivation in the European Union: Practical options for the improvement of the environmental impact-Case study Germany. Online verfügbar unter [https://www.researchgate.net/profile/roberto-molteni/post/what\\_are\\_the\\_best\\_management\\_strategies\\_affordable-farmer-friendly-eco-friendly\\_to\\_mitigate\\_drought\\_stress\\_impacts\\_on\\_corn\\_yield/attachment/610fe2ab647f3906fc8f06d0/as%3a1054530280124416%401628431019137/download/mais\\_allemande.pdf](https://www.researchgate.net/profile/roberto-molteni/post/what_are_the_best_management_strategies_affordable-farmer-friendly-eco-friendly_to_mitigate_drought_stress_impacts_on_corn_yield/attachment/610fe2ab647f3906fc8f06d0/as%3a1054530280124416%401628431019137/download/mais_allemande.pdf).
- ISO 16634-2, 2009: Food products — Determination of the total nitrogen content by combustion according to the Dumas principle and calculation of the crude protein content — Part 2: Food products.
- Fox, J.; Monette, G. (1992): Generalized Collinearity Diagnostics. In: *JASA* 87 (417), S. 178. DOI: 10.2307/2290467.

- Fox, J.; Weisberg, S. (2019): An R companion to applied regression. Third edition. Los Angeles: SAGE.
- FR-FF (2013): Calcul de la fertilisation azotée: guide méthodologique pour l'établissement des prescriptions locales. Cultures annuelles et prairies. Unter Mitarbeit von Comité français d'étude et de développement de la fertilisation raisonnée (COMIFER). Online verfügbar unter <https://comifer.asso.fr/fr/publications.html>, zuletzt geprüft am 19.07.2024.
- Gallais, A.; Hirel, B. (2004): An approach to the genetics of nitrogen use efficiency in maize. In: *J Exp Bot* 55 (396), S. 295–306. DOI: 10.1093/jxb/erh006.
- Ganesh, Siva; Cave, Vanessa (2018): P-values, p-values everywhere! In: *New Zealand Veterinary Journal* 66 (2), S. 55–56. DOI: 10.1080/00480169.2018.1415604.
- Ge, Tida; Sui, Fanggong; Bai, Liping; Tong, Chengli; Sun, Ningbo (2012): Effects of water stress on growth, biomass partitioning, and water-use efficiency in summer maize (*Zea mays* L.) throughout the growth cycle. In: *Acta Physiol Plant* 34 (3), S. 1043–1053. DOI: 10.1007/s11738-011-0901-y.
- Gloser, Vít; Dvorackova, Michaela; Mota, Daniel Hernandez; Petrovic, Bojana; Gonzalez, Patricia; Geilfus, Christoph Martin (2020): Early Changes in Nitrate Uptake and Assimilation Under Drought in Relation to Transpiration. In: *Front. Plant Sci.* 11, S. 602065. DOI: 10.3389/fpls.2020.602065.
- Gonzalez-Dugo, Victoria; Durand, Jean-Louis; Gastal, François (2010): Water deficit and nitrogen nutrition of crops. A review. In: *Agron. Sustain. Dev.* 30 (3), S. 529–544. DOI: 10.1051/agro/2009059.
- Goulding, K. (2000): Nitrate leaching from arable and horticultural land. In: *Soil Use and Management* 16 (s1), S. 145–151. DOI: 10.1111/j.1475-2743.2000.tb00218.x.
- Grömping, U. (2006): Relative Importance for Linear Regression in R: The Package relaimpo. In: *J. Stat. Soft.* 17 (1), S. 1–27. DOI: 10.18637/jss.v017.i01.
- Guan, Yunhao; Zhang, Biwei; Li, Zuoqiang; Zhang, Derun (2025): Enhanced flow number prediction of asphalt mixtures using stacking ensemble-based machine learning model and grey relational analysis. In: *Construction and Building Materials* 463, S. 140001. DOI: 10.1016/j.conbuildmat.2025.140001.
- Guo, J. H.; Liu, X. J.; Zhang, Y.; Shen, J. L.; Han, W. X.; Zhang, W. F. et al. (2010): Significant acidification in major Chinese croplands. In: *Science* 327 (5968), S. 1008–1010. DOI: 10.1126/science.1182570.
- Hartmann, H.P (2002): The use of near infrared spectroscopy in carbon and nitrogen mineralization studies. Dissertation. Leibniz Universität Hannover.
- Hastie, T.; Tibshirani, R.; Friedman, J. H. (2009): The elements of statistical learning: data mining, inference, and prediction: New York: springer. Online verfügbar unter <https://doi.org/10.1007/978-0-387-21606-5>.
- He, Mengqiu; Chen, Shending; Meng, Lei; Dan, Xiaoqian; Wang, Wenjie; Zhu, Qinying et al. (2024): Maize genotypes regulate the feedbacks between maize nitrogen uptake and soil nitrogen transformations. In: *Soil Biology and Biochemistry* 188, S. 109251. DOI: 10.1016/j.soilbio.2023.109251.
- He, Mingzhu; Tang, Liang; Li, Chengyi; Ren, Jianxin; Zhang, Libin; Li, Xinrong (2022): Dynamics of soil organic carbon and nitrogen and their relations to hydrothermal variability in dryland. In: *Journal of Environmental Management* 319, S. 115751. DOI: 10.1016/j.jenvman.2022.115751.
- Heege, H. J.; Reusch, S.; Thiessen, E. (2008): Prospects and results for optical systems for site-specific on-the-go control of nitrogen-top-dressing in Germany. In: *Precision Agric* 9 (3), S. 115–131. DOI: 10.1007/s11119-008-9055-3.
- Heil, Kurt; Schmidhalter, Urs (2021): An Evaluation of Different NIR-Spectral Pre-Treatments to Derive the Soil Parameters C and N of a Humus-Clay-Rich Soil. In: *Sensors* 21 (4), S. 1423. DOI: 10.3390/s21041423.
- Herrmann, A.; Rath, J. (2012): Biogas Production from Maize: Current State, Challenges, and Prospects. 1. Methane Yield Potential. In: *Bioenerg. Res.* 5 (4), S. 1027–1042. DOI: 10.1007/s12155-012-9202-6.
- Herrmann, Antje; Taube, Friedhelm (2004): The Range of the Critical Nitrogen Dilution Curve for Maize (*Zea mays* L.) Can Be Extended Until Silage Maturity. In: *J. Agron.* 96 (4), S. 1131–1138. DOI: 10.2134/agronj2004.1131.
- Herrmann, Antje; Taube, Friedhelm (2005): CORN Nitrogen Concentration at Maturity—An Indicator of Nitrogen Status in Forage Maize. In: *Agronomy Journal* 97 (1), S. 201–210. DOI: 10.2134/agronj2005.0201a.
- Heumann, S.; Fier, A.; Haßdenteufel, M.; Höper, H.; Schäfer, W.; Eiler, T.; Böttcher, J. (2013): Minimizing nitrate leaching while maintaining crop yields: insights by simulating net N mineralization. In: *Fertilizer Research* 95 (3), S. 395–408. DOI: 10.1007/s10705-013-9572-y.
- Heumann, S.; Ratjen, A.; Kage, H.; Böttcher, J. (2014): Estimating net N mineralization under unfertilized winter wheat using simulations with NET N and a balance approach. In: *Fertilizer Research* 99 (1-3), S. 31–44. DOI: 10.1007/s10705-014-9616-y.
- Homyak, Peter M.; Allison, Steven D.; Huxman, Travis E.; Goulden, Michael L.; Treseder, Kathleen K. (2017): Effects of Drought Manipulation on Soil Nitrogen Cycling: A Meta-Analysis. In: *JGR Biogeosciences* 122 (12), S. 3260–3272. DOI: 10.1002/2017JG004146.

- Hothorn, T.; Bretz, F.; Westfall, P.; Heiberger, R. M.; Schuetzenmeister, A.; Scheibe, S.; Hothorn, M. T. (2016): multcomp: Simultaneous Inference in General Parametric Models. Online verfügbar unter <http://ftp5.gwdg.de/pub/misc/cran/web/packages/multcomp/multcomp.pdf>.
- Huang, Mei; Ma, Lina; Chen, Xiaopeng; Zhang, Tao; Guo, Ruiying; Degen, A. Allan; Shang, Zhanhuan (2024): Grazing stabilized carbon and nitrogen pools by reducing carbon and net nitrogen mineralization after soil nutrients were added. In: *Applied Soil Ecology* 201, S. 105509. DOI: 10.1016/j.apsoil.2024.105509.
- Hugh, J. Earl; Richard, F. Davis (2003): Effect of Drought Stress on Leaf and Whole Canopy Radiation Use Efficiency and Yield of Maize. In: *Agronomy Journal* 95 (3), S. 688–696. DOI: 10.2134/agronj2003.6880.
- Imbery, F.; Friedrich, K.; Fleckenstein, R.; Plückhahn, B.; Brömser, A.; Bissolli, P.; ... & Kaspar, F. (2023): Klimatologischer Rückblick auf 2022: Das sonnenscheinreichste und eines der beiden wärmsten Jahre in Deutschland. Online verfügbar unter <https://kommunalwirtschaft.eu/images/presse/pdf/3eb20de1127b9c6d44c21bd1560cf26a-2023-01-20-dwd-klimatologischer-rueckblick-2022.pdf>, zuletzt geprüft am 24.03.2025.
- Inglis, Alan; Parnell, Andrew C.; Subramani, Natarajan; Doohan, Fiona M. (2024): Machine Learning Applied to the Detection of Mycotoxin in Food: A Systematic Review. In: *Toxins* 16 (6), S. 268. DOI: 10.3390/toxins16060268.
- Jaconi, Angélica; Vos, Cora; Don, Axel (2019): Near infrared spectroscopy as an easy and precise method to estimate soil texture. In: *Geoderma* 337, S. 906–913. DOI: 10.1016/j.geoderma.2018.10.038.
- Justes, E. (1994): Determination of a Critical Nitrogen Dilution Curve for Winter Wheat Crops. In: *Annals of Botany* 74 (4), S. 397–407. DOI: 10.1006/anbo.1994.1133.
- Kage, H.; Rübiger, T.; Sieling, K. (2022): Stickstoffdüngung zu Winterraps und Winterweizen. Berichte über Landwirtschaft - Zeitschrift für Agrarpolitik und Landwirtschaft, Aktuelle Beiträge. DOI: 10.12767/BUEL.V1001.415.
- Kayser, Manfred; Benke, Matthias; Isselstein, Johannes (2011): Little fertilizer response but high N loss risk of maize on a productive organic-sandy soil. In: *Agron. Sustain. Dev.* 31 (4), S. 709–718. DOI: 10.1007/s13593-011-0046-9.
- Ke, Fulai; Ma, Xinglin (2021): Responses of maize hybrids with contrasting maturity to planting date in Northeast China. In: *Sci Rep* 11 (1), S. 15776. DOI: 10.1038/s41598-021-95328-5.
- Khan, Nazir A.; Yu, Peiqiang; Ali, Mubarak; Cone, John W.; Hendriks, Wouter H. (2015): Nutritive value of maize silage in relation to dairy cow performance and milk quality. In: *Journal of the Science of Food and Agriculture* 95 (2), S. 238–252. DOI: 10.1002/jsfa.6703.
- Komainda, M.; Taube, F.; Kluß, C.; Herrmann, A. (2018): Effects of catch crops on silage maize (*Zea mays* L.): yield, nitrogen uptake efficiency and losses. In: *Fertilizer Research* 110 (1), S. 51–69. DOI: 10.1007/s10705-017-9839-9.
- Krzebietke, S.; Daszykowski, M.; Czarnik-Matusiewicz, H.; Stanimirova, I.; Pieszczyk, L.; Sienkiewicz, S.; Wierzbowska, J. (2023): Monitoring the concentrations of Cd, Cu, Pb, Ni, Cr, Zn, Mn and Fe in cultivated Haplic Luvisol soils using near-infrared reflectance spectroscopy and chemometrics. In: *Talanta* 251. Jg., S. 123749.
- Kühling, I.; Beiküfner, M.; Vergara, M.; Trautz, D. (2021): Effects of Adapted N-Fertilisation Strategies on Nitrate Leaching and Yield Performance of Arable Crops in North-Western Germany. In: *Agronomy* 11 (1), S. 64. DOI: 10.3390/agronomy11010064.
- Kuhn, M. (2011): The caret package. Online verfügbar unter <http://eio.usc.es/pub/mjginzo/descargas/leyenda/documents/r/win-library/2.12/caret/doc/carettrain.pdf>.
- Kumar, Uttam; Halling, Magnus; Parsons, David; Bergkvist, Göran; Morel, Julien; Vogeler, Iris et al. (2022): Dynamics and plasticity of agronomic performance and nutritive quality traits in forage maize at high latitudes. In: *European Journal of Agronomy* 138, S. 126532. DOI: 10.1016/j.eja.2022.126532.
- Kunrath, Taise Robinson; Lemaire, Gilles; Teixeira, Edmar; Brown, Hamish E.; Ciampitti, Ignacio A.; Sadras, Victor O. (2020): Allometric relationships between nitrogen uptake and transpiration to untangle interactions between nitrogen supply and drought in maize and sorghum. In: *European Journal of Agronomy* 120, S. 126145. DOI: 10.1016/j.eja.2020.126145.
- Lancashire, P. D.; Bleiholder, H.; v. d. Boom, T.; Langelüddeke, P.; Stauss, R.; Weber, E.; Witzemberger, A. (1991): A uniform decimal code for growth stages of crops and weeds. In: *Ann. appl. biol.* 119 (3), S. 561–601. DOI: 10.1111/j.1744-7348.1991.tb04895.x.
- Lee, Sanguk; Choi, Hangseok; Cha, Kyungjoon; Chung, Hoeil (2013): Random forest as a potential multivariate method for near-infrared (NIR) spectroscopic analysis of complex mixture samples: Gasoline and naphtha. In: *Microchemical Journal* 110, S. 739–748. DOI: 10.1016/j.microc.2013.08.007.
- Lemaire, G.; Gastal, F. (1997): N Uptake and Distribution in Plant Canopies. In: G. Lemaire (Hg.): *Diagnosis of the Nitrogen Status in Crops*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 3–43.
- Lemaire, G.; Jeuffroy, M. H.; Gastal, F. (2008): Diagnosis tool for plant and crop N status in vegetative stage: Theory and practices for crop N management. In: *Eur. J. Agron.* (28(4)), S. 614–624. Online verfügbar

- unter  
[https://www.sciencedirect.com/science/article/pii/S1161030108000130?casa\\_token=mg2cmmdbcqaaaaa:a:wkxaex0exo04jqmcf8ja3omq-gjerpjny0rauzudvbxl2ycqjiuxveehvj\\_zzeaf-oy77pjpja](https://www.sciencedirect.com/science/article/pii/S1161030108000130?casa_token=mg2cmmdbcqaaaaa:a:wkxaex0exo04jqmcf8ja3omq-gjerpjny0rauzudvbxl2ycqjiuxveehvj_zzeaf-oy77pjpja).
- Lemaire, Gilles; Ciampitti, Ignacio (2020): Crop Mass and N Status as Prerequisite Covariables for Unraveling Nitrogen Use Efficiency across Genotype-by-Environment-by-Management Scenarios: A Review. In: *Plants* 9 (10), S. 1309. DOI: 10.3390/plants9101309.
- Lenth, R.; Lenth, M. R. (2018): Package 'lsmeans'. Online verfügbar unter <http://r.meteo.uni.wroc.pl/web/packages/lsmeans/lsmeans.pdf>.
- Li, Yuan; Cui, Song; Zhang, Zhixin; Zhuang, Kezhang; Wang, Zhennan; Zhang, Qingping (2020): Determining effects of water and nitrogen input on maize (*Zea mays*) yield, water- and nitrogen-use efficiency: A global synthesis. In: *Sci Rep* 10 (1), S. 9699. DOI: 10.1038/s41598-020-66613-6.
- Link, J.; Graeff, S.; Claupein, W. (2013): Comparison of uniform control and site-specific model-based nitrogen prescription in terms of grain yield, nitrogen use efficiency and economic aspects in a heterogeneous corn field. Online verfügbar unter <https://doi.org/10.5073/JfK.2013.06.03>.
- LIU, Yajuan; CHEN, Yuqi; LIU, Xiuyun; CAI, Siyuan; YUAN, Jiahui; XU, Lingying et al. (2024): Efficiency-enhancing methods for predicting nitrogen mineralization characteristics in paddy soils using soil properties and rapid soil extraction. In: *Pedosphere*. DOI: 10.1016/j.pedsph.2024.10.001.
- LUFA Nord (2023): Maissilageauswertung Maissilageauswertung 15.09.23-28.11.2023. Online verfügbar unter <https://www.lwk-niedersachsen.de/services/download.cfm?file=40699>, zuletzt geprüft am 28.06.2024.
- Mahal, Navreet K.; Osterholz, William R.; Miguez, Fernando E.; Poffenbarger, Hanna J.; Sawyer, John E.; Olk, Daniel C. et al. (2019): Nitrogen Fertilizer Suppresses Mineralization of Soil Organic Matter in Maize Agroecosystems. In: *Front. Ecol. Evol.* 7, Artikel 59, S. 420714. DOI: 10.3389/fevo.2019.00059.
- Makowski, David; Zhao, Ben; Ata-Ul-Karim, Syed Tahir; Lemaire, Gilles (2020): Analyzing uncertainty in critical nitrogen dilution curves. In: *European Journal of Agronomy* 118, S. 126076. DOI: 10.1016/j.eja.2020.126076.
- Mary, B. (1997): Concluding Remarks: N Hazards to Crops and Environment. In: G. Lemaire (Hg.): *Diagnosis of the Nitrogen Status in Crops*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 229–236.
- Mireei, Seyed Ahmad; Mohtasebi, Seyed Saeid; Sadeghi, Morteza (2014): Comparison Of Linear And Non-Linear Calibration Models For Non-Destructive Firmness Determining Of 'Mazafati' Date Fruit By Near Infrared Spectroscopy. In: *International Journal of Food Properties* 17 (6), S. 1199–1210. DOI: 10.1080/10942912.2012.678533.
- Monaco, S.; Sacco, D.; Borda, T.; Grignani, C. (2010): Field measurement of net nitrogen mineralization of manured soil cropped to maize. In: *Biol. Fertil. Soils* 46 (2), S. 179–184. DOI: 10.1007/s00374-009-0412-9.
- Moon, Jihoon; Jung, Seungwon; Rew, Jehyeok; Rho, Seungmin; Hwang, Eenjun (2020): Combination of short-term load forecasting models based on a stacking ensemble approach. In: *Energy and Buildings* 216, S. 109921. DOI: 10.1016/j.enbuild.2020.109921.
- Moreno-Rojas, R.; Cámara-Martos, F.; Amaro López, M.Á. (2015): Sodium: Properties and Determination. In: Benjamin Caballero, Fidel Toldrá und Paul M. Finglas (Hg.): *Encyclopedia of Food and Health*. Burlington, United Kingdom: Elsevier Science, S. 19–23.
- Muon (2015): Stratified splitting the data. Online verfügbar unter Stack Overflow., zuletzt aktualisiert am 12.05.2015.
- Nicolardot, B.; Recous, S.; Mary, B. (2001): Simulation of C and N mineralisation during crop residue decomposition: A simple dynamic model based on the C:N ratio of the residues. In: *Plant and Soil* 228 (1), S. 83–103. DOI: 10.1023/A:1004813801728.
- Ning, Peng; Yang, Lu; Li, Chunjian; Fritsch, Felix B. (2018): Post-silking carbon partitioning under nitrogen deficiency revealed sink limitation of grain yield in maize. In: *J Exp Bot* 69 (7), S. 1707–1719. DOI: 10.1093/jxb/erx496.
- Oliveira, Karym Mayara de; Gonçalves, João Vitor Ferreira; Furlanetto, Renato Herrig; Oliveira, Caio Almeida de; Mendonça, Wesley Augusto; Da Haubert, Daiane de Fatima Silva et al. (2024): Predicting Particle Size and Soil Organic Carbon of Soil Profiles Using VIS-NIR-SWIR Hyperspectral Imaging and Machine Learning Models. In: *Remote Sensing* 16 (16), S. 2869. DOI: 10.3390/rs16162869.
- Pandey, R. K.; Maranville, J. W.; Chetima, M. M. (2000): Deficit irrigation and nitrogen effects on maize in a Sahelian environment: II. Shoot growth, nitrogen uptake and water extraction. Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/S0378377400000743>.
- Park, Y. S.; Lek, S. (2016): Artificial neural networks: Multilayer perceptron for ecological modeling. In: *Developments in environmental modelling* (Vol. 28), pp. 123-140. Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/B9780444636232000074>.

- Peichl, Michael; Thober, Stephan; Samaniego, Luis; Hansjürgens, Bernd; Marx, Andreas (2019): Climate impacts on long-term silage maize yield in Germany. In: *Sci Rep* 9 (1), S. 7674. DOI: 10.1038/s41598-019-44126-1.
- Philippeau, C.; Michalet-Doreau, B. (1997): Influence of genotype and stage of maturity of maize on rate of ruminal starch degradation. In: *Animal Feed Science and Technology* 68 (1-2), S. 25–35. DOI: 10.1016/s0377-8401(97)00042-4.
- Piepho, H. P.; Edmondson, R. N. (2018): A tutorial on the statistical analysis of factorial experiments with qualitative and quantitative treatment factor levels. In: *Journal of Agronomy and Crop Science* 204 (5), S. 429–455. DOI: 10.1111/jac.12267.
- Pinheiro, José; Bates, Douglas (2025): nlme. Linear and Nonlinear Mixed Effects Models. Online verfügbar unter <https://svn.r-project.org/R-packages/trunk/nlme/>.
- Plénet, D.; Cruz, P. (1997): Maize and Sorghum. In: G. Lemaire (Hg.): *Diagnosis of the Nitrogen Status in Crops*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 93–106.
- Plénet, Daniel; Lemaire, Gilles (1999): Relationships between dynamics of nitrogen uptake and dry matter accumulation in maize crops. Determination of critical N concentration. In: *Plant and Soil* 216 (1/2), S. 65–82. DOI: 10.1023/A:1004783431055.
- Poorter, Hendrik; Niklas, Karl J.; Reich, Peter B.; Oleksyn, Jacek; Poot, Pieter; Mommer, Liesje (2012): Biomass allocation to leaves, stems and roots: meta-analyses of interspecific variation and environmental control. In: *New Phytologist* 193 (1), S. 30–50. DOI: 10.1111/j.1469-8137.2011.03952.x.
- Proteinmarkt (2022): Ergebnisse der Maissilage Ernte 2022. Online verfügbar unter [https://www.proteinmarkt.de/aktuelles/futtermittel/details-1/news/ergebnisse-der-maissilage-ernte-2022#:~:text=Die%20Mittelwerte%20des%20Rohproteingehalts%20liegen,Brandenburg\), zuletzt geprüft am 28.06.2024](https://www.proteinmarkt.de/aktuelles/futtermittel/details-1/news/ergebnisse-der-maissilage-ernte-2022#:~:text=Die%20Mittelwerte%20des%20Rohproteingehalts%20liegen,Brandenburg), zuletzt geprüft am 28.06.2024).
- Puntel, Laila A.; Sawyer, John E.; Barker, Daniel W.; Thorburn, Peter J.; Castellano, Michael J.; Moore, Kenneth J. et al. (2018): A Systems Modeling Approach to Forecast Corn Economic Optimum Nitrogen Rate. In: *Front. Plant Sci.* 9, S. 436. DOI: 10.3389/fpls.2018.00436.
- R Core Team (2022): R: A language and environment for statistical computing. R Foundation for Statistical Computing. Version 4.1.0. Vienna, Austria.
- R Core Team (2023): R: A language and environment for statistical computing. R Foundation for Statistical Computing. Version 4.1.2. Vienna, Austria. Online verfügbar unter <https://www.R-project.org>.
- Ratjen, A. M.; Kage, H. (2015): Forecasting yield via reference- and scenario calculations. In: *Computers and Electronics in Agriculture* 114, S. 212–220. DOI: 10.1016/j.compag.2015.03.020.
- Ratjen, A. M.; Lemaire, G.; Kage, H.; Plénet, D.; Justes, E. (2018): Key variables for simulating leaf area and N status: Biomass based relations versus phenology driven approaches. In: *Eur. J. Agron.* 100, S. 110–117. DOI: 10.1016/j.eja.2018.04.008.
- Ratjen, Arne M.; Kage, Henning (2018): Predicting the site specific soil N supply under winter wheat in Germany. In: *Fertilizer Research* 110 (1), S. 71–81. DOI: 10.1007/s10705-017-9850-1.
- Reijneveld, Jan Adriaan; van Oostrum, Martijn Jasper; Brolsma, Karst Michiel; Fletcher, Dale; Oenema, Oene (2022): Empower Innovations in Routine Soil Testing. In: *Agronomy* 12 (1), S. 191. DOI: 10.3390/agronomy12010191.
- Rinnan, Åsmund; van Berg, Frans den; Engelsen, Søren Balling (2009): Review of the most common pre-processing techniques for near-infrared spectra. In: *TrAC Trends in Analytical Chemistry* 28 (10), S. 1201–1222. DOI: 10.1016/j.trac.2009.07.007.
- Ripley, B.; Venables, B.; Bates, D. M.; Hornik, K.; Gebhardt, A.; Firth, D. (2024): MASS: Support Functions and Datasets for Venables and Ripley's MASS. Version 7.3-60.0.1.
- Rodrigo, Alfredo; Recous, Sylvie; Neel, Catherine; Mary, Bruno (1997): Modelling temperature and moisture effects on C–N transformations in soils: comparison of nine models. In: *Ecological Modelling* 102 (2-3), S. 325–339. DOI: 10.1016/s0304-3800(97)00067-7.
- Ros, Gerard H.; Hanegraaf, Marjoleine C.; Hoffland, Ellis; van Riemsdijk, Willem H. (2011): Predicting soil N mineralization: Relevance of organic matter fractions and soil properties. In: *Soil Biology and Biochemistry* 43 (8), S. 1714–1722. DOI: 10.1016/j.soilbio.2011.04.017.
- Rose, M.; Pahlmann, I.; Kage, H. (2023): Modified crop rotations for a sustainable intensification? A case study in a high-yielding environment with recurrent nitrogen surplus. In: *Eur. J. Agron.* 142, S. 126644. DOI: 10.1016/j.eja.2022.126644.
- Rudolf, J.; Brandt, J.; Velthof, G.; Ros, M.; Schipper, P.; Yanjiao, M. et al. (2021): Recommendations of the Most Promising Package(s) of Measures, Policies, Governance Models and Tools at National and EU Level. In: *FAIRWAY project and partners*.
- Ruma, Farida Yasmin; Munaf, Muhammad Abdul; Neve, Stefaan de; Mouazen, Abdul Mounem (2024a): Visible and near infrared spectroscopy for predicting soil nitrogen mineralization rate: Effect of incubation period and ancillary soil properties. In: *CATENA* 235, S. 107649. DOI: 10.1016/j.catena.2023.107649.

- Ruma, Farida Yasmin; Munnaf, Muhammad Abdul; Neve, Stefaan de; Mouazen, Abdul Mounem (2024b): Visible-to-near-infrared spectroscopy for prediction of soil nitrogen mineralization after sample stratification by textural homogeneity criteria. In: *Soil and Tillage Research* 244, S. 106250. DOI: 10.1016/j.still.2024.106250.
- Samadi; Wajizah, Sitti; Munawar, Agus Arip (2020): Near infrared spectroscopy (NIRS) data analysis for a rapid and simultaneous prediction of feed nutritive parameters. In: *Data in Brief* 29, S. 105211. DOI: 10.1016/j.dib.2020.105211.
- Sandaña, Patricio; Lizana, Carolina X.; Pinochet, Dante; Soratto, Rogério P. (2025): The nitrogen nutrition index as a tool to assess nitrogen use efficiency in potato genotypes. In: *European Journal of Agronomy* 162, S. 127397. DOI: 10.1016/j.eja.2024.127397.
- Santana, Felipe B. de; Otani, Sandro K.; Souza, André M. de; Poppi, Ronei J. (2021): Comparison of PLS and SVM models for soil organic matter and particle size using vis-NIR spectral libraries. In: *Geoderma Regional* 27, e00436. DOI: 10.1016/j.geodrs.2021.e00436.
- Santasup, Natchanon; Theanjumpol, Parichat; Santasup, Choochard; Kittiwachana, Sila; Mawan, Nipon; Prantong, Lalicha; Khongdee, Nuttapon (2024): Development of near-infrared spectroscopy (NIRS) for estimating organic matter, total carbon, and total nitrogen in agricultural soil. In: *MethodsX* 13, S. 102798. DOI: 10.1016/j.mex.2024.102798.
- Sarkar, Shagor; Basak, Jayanta Kumar; Moon, Byeong Eun; Kim, Hyeon Tae (2020): A Comparative Study of PLSR and SVM-R with Various Preprocessing Techniques for the Quantitative Determination of Soluble Solids Content of Hardy Kiwi Fruit by a Portable Vis/NIR Spectrometer. In: *Foods* 9 (8), S. 1078. DOI: 10.3390/foods9081078.
- Schimel, Joshua P.; Bennett, Jennifer (2004): Nitrogen mineralization: challenges of a changing paradigm. In: *Ecology* 85 (3), S. 591–602. DOI: 10.1890/03-8002.
- Schmidt, Fruzsina; Böhm, Herwart; Piepho, Hans-Peter; Urbatzka, Peer; Wachendorf, Michael; Graß, Rüdiger (2023): Yield stability of silage maize double cropping systems across nine German environments. In: *Front. Agron.* 5, Artikel 1235034. DOI: 10.3389/fagro.2023.1235034.
- Schröder, J. J. (1999): Effect of split applications of cattle slurry and mineral fertilizer–N on the yield of silage maize in a slurry-based cropping system. In: *Nutr. Cycl. Agroecosyst* 53 (3), S. 209–218. DOI: 10.1023/A:1009796021850.
- Schröder, J. J.; Neeteson, J. J.; Oenema, O.; Struik, P. C. (2000): Does the crop or the soil indicate how to save nitrogen in maize production?: Reviewing the state of the art. In: *Field Crops Res.* (66(2)), S. 151–164. Online verfügbar unter [https://www.sciencedirect.com/science/article/pii/S0378429000000721?casa\\_token=ynbpwxiaebgaaaaa:Ogh3telx\\_jf-qr1vadsphf8klf0hmgcps5hynzhfv31cxtsiemxgcp3e7nl0ixtawghj1eh3w](https://www.sciencedirect.com/science/article/pii/S0378429000000721?casa_token=ynbpwxiaebgaaaaa:Ogh3telx_jf-qr1vadsphf8klf0hmgcps5hynzhfv31cxtsiemxgcp3e7nl0ixtawghj1eh3w).
- Seidel, S. J.; Ahmadi, S. H.; Weihermüller, L.; Couédel, A.; Lopez, G.; Behrend, D. et al. (2024): The overlooked effects of environmental impacts on root:shoot ratio in experiments and soil-crop models. In: *The Science of the total environment* 955, S. 176738. DOI: 10.1016/j.scitotenv.2024.176738.
- Seifi, Mahmood; Ahmadi, Abbas; Neyshabouri, Mohamad-Reza; Taghizadeh-Mehrpardi, Ruhollah; Bahrami, Hossein-Ali (2020): Remote and Vis-NIR spectra sensing potential for soil salinization estimation in the eastern coast of Urmia hyper saline lake, Iran. In: *Remote Sensing Applications: Society and Environment* 20, S. 100398. DOI: 10.1016/j.rsase.2020.100398.
- Shao, Hui; Miao, Yuxin; Fernández, Fabián G.; Kitchen, Newell R.; Ransom, Curtis J.; Camberato, James J. et al. (2023): Evaluating Critical Nitrogen Dilution Curves for Assessing Maize Nitrogen Status across the US Midwest. In: *Agronomy* 13 (7), S. 1948. DOI: 10.3390/agronomy13071948.
- Sharma, Sanjula; Goyal, Prinka; Devi, Jomika; Atri, Chhaya; Kumar, Ravinder; Banga, S. S. (2024): Using near-infrared reflectance spectroscopy (NIRS) to predict the nitrogen levels in the stem and root tissues of Brassica juncea (Indian mustard). In: *Spectrochimica acta. Part A, Molecular and biomolecular spectroscopy* 322, S. 124755. DOI: 10.1016/j.saa.2024.124755.
- Sieling, Klaus; Böttcher, Ulf; Kage, Henning (2013): Growth stage specific optima for the green area index of winter wheat. In: *Field Crops Research* 148, S. 34–42. DOI: 10.1016/j.fcr.2013.04.002.
- Sieling, Klaus; Kage, Henning (2021): Organ-specific critical N dilution curves and derived NNI relationships for winter wheat, winter oilseed rape and maize. In: *European Journal of Agronomy* 130, S. 126365. DOI: 10.1016/j.eja.2021.126365.
- Sim, Joy; McGoverin, Cushla; Oey, Indrawati; Frew, Russell; Kebede, Biniam (2024): Non-linear machine learning coupled near infrared spectroscopy enhanced model performance and insights for coffee origin traceability. In: *J. Near Infrared Spectrosc., JNIRS* 32 (4-5), S. 127–139. DOI: 10.1177/09670335241269014.
- Snyder, C. S.; Bruulsema, T. W.; Jensen, T. L.; Fixen, P. E. (2009): Review of greenhouse gas emissions from crop production systems and fertilizer management effects. In: *Agriculture, Ecosystems & Environment* 133 (3-4), S. 247–266. DOI: 10.1016/j.agee.2009.04.021.

- Soinne, Helena; Keskinen, Riikka; Rätty, Mari; Kanerva, Sanna; Turtola, Eila; Kaseva, Janne et al. (2021): Soil organic carbon and clay content as deciding factors for net nitrogen mineralization and cereal yields in boreal mineral soils. In: *European Journal of Soil Science* 72 (4), S. 1497–1512. DOI: 10.1111/ejss.13003.
- Stenberg, Bo; Viscarra Rossel, Raphael A.; Mouazen, Abdul Mounem; Wetterlind, Johanna (2010): Visible and Near Infrared Spectroscopy in Soil Science. In: *Advances in Agronomy*: Elsevier, S. 163–215.
- Struck, Inger Julia; Reinsch, Thorsten; Herrmann, Antje; Kluß, Christof; Loges, Ralf; Taube, Friedhelm (2019): Yield potential and nitrogen dynamics of no-till silage maize (*Zea mays* L.) under maritime climate conditions. In: *European Journal of Agronomy* 107, S. 30–42. DOI: 10.1016/j.eja.2019.04.009.
- Svoboda, Nikolai; Taube, Friedhelm; Kluß, Christof; Wienforth, Babette; Kage, Henning; Ohl, Susanne et al. (2013): Crop production for biogas and water protection—A trade-off? In: *Agriculture, Ecosystems & Environment* 177, S. 36–47. DOI: 10.1016/j.agee.2013.05.024.
- Tang, Ke; Zhao, Xing; Xu, Zong; Sun, Huojiao (2024): A stacking ensemble model for predicting soil organic carbon content based on visible and near-infrared spectroscopy. In: *Infrared Physics & Technology* 140, S. 105404. DOI: 10.1016/j.infrared.2024.105404.
- Tang, Li Jun; Li, Xin Kang; Huang, Yue; Zhang, Xiang-Zhi; Li, Bao Qiong (2025): A novel importance scores based variable selection approach and validation using a MIR and NIR dataset. In: *Spectrochimica Acta. Part A, Molecular and biomolecular spectroscopy* 330, S. 125701. DOI: 10.1016/j.saa.2025.125701.
- Teixeira, Edmar I.; George, Michael; Herreman, Thibault; Brown, Hamish; Fletcher, Andrew; Chakwizira, Emmanuel et al. (2014): The impact of water and nitrogen limitation on maize biomass and resource-use efficiencies for radiation, water and nitrogen. In: *Field Crops Research* 168, S. 109–118. DOI: 10.1016/j.fcr.2014.08.002.
- Theiß, M.; Schliephake, W. (2020): Aussage von Nmin-Untersuchungen nach der Ernte. Online verfügbar unter <https://slub.qucosa.de/id/qucosa:76754>.
- Umweltbundesamt (UBA) (2023): Development of Germany's climate. Monitoring report 2023. Online verfügbar unter [https://www.umweltbundesamt.de/en/monitoring-on-das/development?utm\\_source=chatgpt.com#the-development-of-germanys-climate-since-the-end-of-the-19th-century](https://www.umweltbundesamt.de/en/monitoring-on-das/development?utm_source=chatgpt.com#the-development-of-germanys-climate-since-the-end-of-the-19th-century).
- Umweltbundesamt (UBA) (2024): Chemischer Zustand des Grundwassers. Online verfügbar unter <https://www.umweltbundesamt.de/themen/wasser/grundwasser/zustand-des-grundwassers/chemischer-zustand-des-grundwassers/1000>, zuletzt geprüft am 27.06.2024.
- Unterseer, Sandra; Pophaly, Saurabh D.; Peis, Regina; Westermeier, Peter; Mayer, Manfred; Seidel, Michael A. et al. (2016): A comprehensive study of the genomic differentiation between temperate Dent and Flint maize. In: *Genome Biol* 17 (1), S. 137. DOI: 10.1186/s13059-016-1009-x.
- Velthof, G.; van Schooten, H.; van Dijk, W. (2020): Optimization of the Nutrient Management of Silage Maize Cropping Systems in The Netherlands: A Review. In: *Agronomy* 10 (12), S. 1861. DOI: 10.3390/agronomy10121861.
- Vos, J.; van der Putten, P.E.L.; Birch, C. J. (2005): Effect of nitrogen supply on leaf appearance, leaf growth, leaf nitrogen economy and photosynthetic capacity in maize (*Zea mays* L.). In: *Field Crops Research* 93 (1), S. 64–73. DOI: 10.1016/j.fcr.2004.09.013.
- Wadoux, Alexandre M.J.-C.; Malone, Brendan; Minasny, Budiman; Fajardo, Mario; McBratney, Alex B. (2021): Soil Spectral Inference with R. Analysing Digital Soil Spectra using the R Programming Environment. 1st ed. 2021. Cham: Springer International Publishing; Imprint Springer (Progress in Soil Science).
- Wang, Qiaoyun; Zou, Xin; Chen, Yinji; Zhu, Ziheng; Yan, Chongyue; Shan, Peng et al. (2024): Xgboost Algorithm Assisted Multi-Component Quantitative Analysis with Raman Spectroscopy: Elsevier BV.
- Wang, S.; Adhikari, K.; Wang, Q.; Jin, X.; Li, H. (2018): Role of environmental variables in the spatial distribution of soil carbon (C), nitrogen (N), and C: N ratio from the northeastern coastal agroecosystems in China. In: *Ecological indicators* (84), S. 263–272. Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/S1470160X17305368>.
- Wang, Yang; Huang, Yufang; Fu, Wen; Guo, Wenqing; Ren, Ning; Zhao, Yanan; Ye, Youliang (2020): Efficient Physiological and Nutrient Use Efficiency Responses of Maize Leaves to Drought Stress under Different Field Nitrogen Conditions. In: *Agronomy* 10 (4), S. 523. DOI: 10.3390/agronomy10040523.
- Watson, Catherine J. (1996): Grassland Nitrogen, by D. C. Whitehead. xv + 385 pp. Wallingford: CAB International (1995). £49.95 or \$90.00 (hardback). ISBN 0 85198 915 2. In: *J. Agric. Sci.* 126 (3), S. 376–377. DOI: 10.1017/s0021859600075031.
- Werner, Lena Maria; Hartwig, Roman Paul; Engel, Isabelle; Franzisky, Bastian Leander; Wienkoop, Stefanie; Brenner, Martin et al. (2022): Local and systemic metabolic adjustments to drought in maize: Hydraulic redistribution in a split-root system. In: *J. Plant Nutr. Soil Sci.* 185 (5), S. 632–642. DOI: 10.1002/jpln.202200279.
- Wickham, Hadley (2016): modelr: Modelling Functions that Work with the Pipe. In: *CRAN: Contributed Packages*. DOI: 10.32614/cran.package.modelr.

- Wienforth, B. (2011): Cropping systems for biomethane production: a simulation based analysis of yield, yield potential and resource use efficiency. (Dissertation).
- Winterhalter, Loïc; Mistele, Bodo; Schmidhalter, Urs (2012): Assessing the vertical footprint of reflectance measurements to characterize nitrogen uptake and biomass distribution in maize canopies. In: *Field Crops Research* 129, S. 14–20. DOI: 10.1016/j.fcr.2012.01.007.
- Wittich, Klaus-Peter; Liedtke, Marco (2015): Shifts in plant phenology: a look at the sensitivity of seasonal phenophases to temperature in Germany. In: *Intl Journal of Climatology* 35 (13), S. 3991–4000. DOI: 10.1002/joc.4262.
- Wu, Yongshen; Liu, Wenguo; Li, Xinhai; Li, Mingshun; Zhang, Degui; Hao, Zhuanfang et al. (2011): Low-nitrogen stress tolerance and nitrogen agronomic efficiency among maize inbreds: comparison of multiple indices and evaluation of genetic variation. In: *Euphytica* 180 (2), S. 281–290. DOI: 10.1007/s10681-011-0409-y.
- Ye, Miao; Zhu, Lin; Li, Xiaojuan; Ke, Yinghai; Huang, Yong; Chen, Beibei et al. (2023): Estimation of the soil arsenic concentration using a geographically weighted XGBoost model based on hyperspectral data. In: *The Science of the total environment* 858 (Pt 1), S. 159798. DOI: 10.1016/j.scitotenv.2022.159798.
- Yue, Shan-Chao; Sun, Fu-Lai; Meng, Qing-Feng; Zhao, Rong-Fang; Li, Fei; Chen, Xin-Ping et al. (2014): Validation of a Critical Nitrogen Curve for Summer Maize in the North China Plain. In: *Pedosphere* 24 (1), S. 76–83. DOI: 10.1016/s1002-0160(13)60082-x.
- Zayani, Hayfa; Fouad, Youssef; Michot, Didier; Kassouk, Zeineb; Baghdadi, Nicolas; Vaudour, Emmanuelle et al. (2023): Using Machine-Learning Algorithms to Predict Soil Organic Carbon Content from Combined Remote Sensing Imagery and Laboratory Vis-NIR Spectral Datasets. In: *Remote Sensing* 15 (17), S. 4264. DOI: 10.3390/rs15174264.
- Zhang, Ling; Liang, Zheng-yuan; He, Xiao-ming; Meng, Qing-Feng; Hu, Yuncai; Schmidhalter, Urs et al. (2020): Improving grain yield and protein concentration of maize (*Zea mays* L.) simultaneously by appropriate hybrid selection and nitrogen management. In: *Field Crops Research* 249, S. 107754. DOI: 10.1016/j.fcr.2020.107754.
- Zhang, Wengang; Gu, Xin; Hong, Li; Han, Liang; Wang, Lin (2023): Comprehensive review of machine learning in geotechnical reliability analysis: Algorithms, applications and further challenges. In: *Applied Soft Computing* 136, S. 110066. DOI: 10.1016/j.asoc.2023.110066.
- Zhang, X.; Wang, Q.; Gilliam, F. S.; Bai, W.; Han, X.; Li, L. (2012): Effect of nitrogen fertilization on net nitrogen mineralization in a grassland soil, northern China. In: *Grass Forage Sci.* 67 (2), S. 219–230. DOI: 10.1111/j.1365-2494.2011.00836.x.
- Zhong, Kangyuan; Li, Yane; Huan, Weiwei; Weng, Xiang; Wu, Bin; Chen, Zheyi et al. (2024): A novel near infrared spectroscopy analytical strategy for soil nutrients detection based on the DBO-SVR method. In: *Spectrochimica acta. Part A, Molecular and biomolecular spectroscopy* 315, S. 124259. DOI: 10.1016/j.saa.2024.124259.
- Ziadi, Noura; Brassard, Marianne; Bélanger, Gilles; Claessens, Annie; Tremblay, Nicolas; Cambouris, Athyna N. et al. (2008): Chlorophyll Measurements and Nitrogen Nutrition Index for the Evaluation of Corn Nitrogen Status. In: *Agronomy Journal* 100 (5), S. 1264–1273. DOI: 10.2134/agronj2008.0016.
- Zou, Xin; Wang, Qiaoyun; Chen, Yinji; Wang, Jilong; Xu, Shunyuan; Zhu, Ziheng et al. (2024): Fusion of Convolutional Neural Network with Xgboost Feature Extraction for Predicting Multi-Constituents in Corn Using Near Infrared Spectroscopy. In: *Food Chemistry* (463), Artikel 141053. DOI: 10.2139/ssrn.4861619.

## 2. Verwertung

### a) Erfindungen/Schutzrechtsanmeldungen

trifft nicht zu

### b) Wirtschaftliche Erfolgsaussichten nach Projektende

trifft nicht zu

### c) Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende

- Die im Rahmen der Feldversuche generierten Daten sowie die Erkenntnisse des Projektes zur Mineralisation der organischen Bodensubstanz und das weiterentwickelte Prozessmodell HUME-Maize werden in Kombination mit weiteren laufenden Projekten an der CAU (z.B. MuD Vorhaben BMEL Demonstrationsbetriebe Integrierter Pflanzenbau) die Modellierung des N-Haushalts in Anbausystemen deutlich voranbringen. Dies stellt einen wichtigen Schritt zum Entwurf und der Bewertung standortgerechter, klima- und umweltfreundlicher Landnutzungssysteme dar.
- Aus der Weiterarbeit an dieser Thematik sollen an der CAU weitere peer-reviewed Publikationen in internationalen und nationalen Praxisjournalen sowie Präsentationen auf Konferenzen hervorgehen.
- Die Regressionsmodelle zur UAV-basierten Erfassung von Silomaisbestandesparametern ermöglichen die effiziente Erhebung zeitlich und räumlich hochaufgelösterer Daten. Dies wird in Zukunft einen erheblichen Mehrwert bei Feldversuchen für Projektpartner, und durch die Veröffentlichung der Kalibrationen auch für andere wissenschaftliche Institute und die landwirtschaftliche Beratung generieren.
- Skripte für den automatisierten Download von Boden- und Witterungsdaten von Onlinedatenbanken werden in weiteren Projekten verwendet.

### d) Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

- Der Erfahrungen und Ergebnisse beim Testen der modernen Sensorik (UAV, NIRS) werden in weiteren CAU-Projekten genutzt, beispielsweise zur zeitsparenden Erhebung von Silomaisbestandesparametern im Projekt RootWayS, Phase II.
- Mit den entwickelten Schätzmodellen zur Nettomineralisation und N-Düngeoptimum können pflanzenbauliche Fragestellungen rund um Möglichkeiten zur Weiterentwicklung der Düngeverordnung wissenschaftlich fundiert erarbeitet werden.
- Basierend auf den Erkenntnissen aus den Versuchen wird die prozessorientierte dynamische Modellierung des N-Haushaltes und somit die Weiterentwicklung von Internet-basierten Düngeberatungsplattformen vorangetrieben.
- Durch intensive Mitarbeit von Nachwuchswissenschaftlerinnen und Nachwuchswissenschaftlern im Rahmen des Projekts wird langfristig Fachpersonal für die Bearbeitung dieser und ähnlicher Fragen der nachhaltigen Landnutzung qualifiziert.
- Durch die enge Zusammenarbeit mit verschiedenen Landwirtschaftskammern und Länderdienststellen wurden im Laufe des Projektes neue Auswertungsideen und wissenschaftliche Fragestellungen entwickelt, die in AP3 bereits zum Teil adressiert werden, jedoch auch die Grundlage für einen neuen Projektantrag darstellen könnten.

## 3. Erkenntnisse von Dritten

- Ohne die im RootWayS-Projekt erhobenen Daten und die durch die darin angestellte Doktorandin Frau Holzhauser erfolgten Arbeiten am HUME-Maize-Modell wäre die Arbeiten in diesem Maß nicht realisierbar gewesen.
- Die von der LWK Niedersachsen beobachteten Zusammenhänge von einer zu hohen Düngung und einem erhöhten N<sub>min</sub> nach Ernte, weswegen letzterer auch als zu verwendender Zielparameter für eine ausgeglichene N-Bilanz diskutiert wird, wurden im Rahmen von AP3 weiter untersucht.

## 4. Veröffentlichungen

Bukowiecki, J., Rose, T., Holzhauser, K., Rothardt, ... & Kage, H. (2024). UAV-based canopy monitoring: calibration of a multispectral sensor for green area index and nitrogen uptake across several crops. *Precision Agriculture*, 25(3), 1556-1580.

Bukowiecki, J., Ullrich, L., Komainda, M., Herrmann, ... & Kühling, I. (under review). A closer look at European fertilizer legislations for silage maize: Part I – inaccurate account of net nitrogen mineralization.

Bukowiecki, J., Ullrich, L., Komainda, M., Herrmann, ... & Kühling, I. (under review). A closer look at European fertilizer legislation for silage maize: Part II - overestimation of economically optimal nitrogen rates.

Holzhauser, K., Wienforth, B., Komainda, M., Herrmann, A., ... & Bukowiecki, J. (in preparation). HUME-Maize: A dynamic crop growth model for silage maize (*Zea mays* L.).

Khatun, F., Herrmann, A., Bukowiecki, J., Asabere S., Schwarz, F., Kage, H., Grunwald, D., Koch, H.-J., Möller, K., Isselstein, J. Komainda, M. (in preparation). Near-Infrared-Reflectance spectroscopy (NIRS) for predicting soil nitrogen mineralization. *Soil Use and Management*

Komainda M., Bukowiecki, J., Herrmann, A., Kayser, M., Schwarz, F., Kage, H., Isselstein, J. (in preparation). Improving nitrogen use efficiency of silage maize (*Zea mays* L.) by choice of hybrid maturity rate under contrasting environmental conditions?

Komainda M., Bukowiecki, J., Herrmann, A., Kayser, M., Schwarz, F., Kage, H., Isselstein, J. (in preparation). Efficiency of organic fertilizer application in silage maize (*Zea mays* L.) as affected by drought conditions.

Lamega, S.A., Bukowiecki, J., Herrmann, A., Schwarz, F., Kage, H., Isselstein, J., Komainda, M. (in preparation). Relative biomass allocation of three maize hybrids differing in maturity rate under contrasting environmental conditions and nitrogen deficiency.

Schwarz, F., Kayser, M., Bukowiecki, J., Herrmann, A., ... & Komainda, M. (in preparation). No variation in critical nitrogen curves of modern maize hybrids differing in maturity rate grown under contrasting environmental conditions. *Journal of Plant Nutrition and Soil Science*

Bukowiecki, J., Ullrich, L., Kage, H., M., Herrmann, ... & Komainda, M. (in preparation). Economic and Ecological Trade-Offs in Silage Maize N Fertilization: Balancing returns and post-harvest soil mineral nitrogen.

### **Veröffentlichungen (non-peer-reviewed)**

Komainda, M., Khatun, F., Schwarz, F., Isselstein, J., .... & Herrmann, A. (2025). Big Data im Pflanzenbau: mit KI zu besserer Düngeplanung im Mais? *Land ohne Pflug*.

Bukowiecki, J., Holzhauser, K., Kage, H., Herrmann, A. und Komainda, M. (2023). Stickstoffdynamik im Mais mithilfe von Drohnen besser verstehen. *Mais 50*, Heft 3.

### **Vorträge auf wissenschaftlichen Konferenzen**

Bukowiecki, J., Ullrich, L., Komainda, M., Herrmann, A. Kühling, I. Kage, H. (2024): Optimizing N fertilization in silage maize: consideration of site and management leads to savings compared to official recommendations. XXII International N workshop, Aarhus Dänemark, 17-21.06.2024.

Bukowiecki, J., Ullrich, L., Komainda, M., Herrmann, A. and Kage, H. (2023): Site and Management Effects on Maize N Fertilization Demand. ASA, CSSA, SSSA International Annual Meeting, St. Louis, MO, USA.

Bukowiecki, J., Komainda, M., Ullrich, L., Herrmann, A. und Kage, H. (2023): Standort- und Management-Effekte auf die Nettomineralisation im Maisanbau. *Mitt. Ges. Pflanzenbauwiss.* 33, 45–46.

Bukowiecki, J., Holzhauser, K. und Kage, H. (2022): Silage Maize Yield Estimation: UAV-based Assessment of Relevant Crop Parameters. XVII. Congress of the European Society for Agronomy, 29th August- 2nd September 2022, Potsdam, Germany, S. 185-186.

Komainda, M., Herrmann, A., Bukowiecki, J., Schwarz, F., Kayer, M., Kage, H., Isselstein, J. (2023). NIRS-gestützte Modellierung der N-Nachlieferung im Maisanbau. *Mitt. Ges. Pflanzenbauwiss.* 33, 163-164.

Schwarz, F., Kayser, M., Herrmann, A., Isselstein, J., Komainda, M. (2023). Die Untersuchung von N-Effizienz in Silomais unter Zuhilfenahme von Chlorophyllwerten. *Mitt. Ges. Pflanzenbauwiss.* 33, 189-190.

### **Vorträge zum Wissenstransfer**

Bukowiecki, J. (2024): Düngebedarf im Silomais – standortspezifische Perspektiven. Feldtag Versuchsgut Hohenschulen am 06.06.2024, Achterwehr.

Bukowiecki, J. (2024): Optimierung der N-Düngung im Silomaisanbau: Berücksichtigung von Standort und Managementeffekten. Veranstaltung Ergebnistransfer Landwirtschaft und Wasserschutz am 13.03.2024, Hannover.

# ANHANG

## **Teilvorhaben 1: Modellgestützte Analyse der N-Effizienz im Maisanbau durch Verbesserung der Ertragsprognose unter Zuhilfenahme spektraler Daten, Christian-Albrechts-Universität zu Kiel, Institut für Pflanzenbau und Pflanzenzüchtung, Abteilung Acker- und Pflanzenbau**

### **1. Ziel und Gegenstand des Teilvorhabens**

Übergeordnetes Ziel des Projekt NEffMais war es, zur Erhöhung der Stickstoff (N)-Nutzungseffizienz im Silomaisanbau beizutragen. Der Fokus der Arbeiten lag hierbei in der Erfassung, Modellierung und Prognose der Ertragsbildung und N-Dynamik im Silomaisanbau. Ziel des CAU-Teilvorhabens war hierbei die Entwicklung von empirischen Modellen zum Drohnen-basierten Monitoring der Silomaisentwicklung sowie von Regressionsmodellen zur Abschätzung der ganzsaisonalen N-Nettomineralisation und des N-Düngeoptimums zu Beginn der Silomaisaison. Ein bereits vorliegendes Prozessmodell zur Ertragsbildung im Silomais sollte basierend auf diesen Erkenntnissen weiterentwickelt werden und dessen Genauigkeit das N-Düngeoptimum zu prognostizieren evaluiert werden. Grundlage für diese Arbeiten bildeten umfangreiche Feldversuche der drei Projektpartner an drei Standorten und zwei Jahren. Der CAU oblag die Koordination dieser Feldversuche sowie des gesamten Projektes inklusive des Datenmanagements und der Öffentlichkeitsarbeit.

### **2. Bearbeitete Arbeitspakete**

#### **Arbeitspaket 0: Projektkoordination/ Öffentlichkeitsarbeit**

Die Projektkoordination wurde von der CAU Kiel übernommen und umfasste die Organisation von Versuchsaktivitäten, Projekttreffen, Meilenstein-Überprüfung und Berichterstattung. Projekttreffen fanden regelmäßig online statt, während Präsenztreffen in Wehnen (2021) und Hohenschulen (2022) sowie ein Stakeholder-Workshop (2023) abgehalten wurden. Im Rahmen der Feldversuche entstanden mehrere wissenschaftliche Publikationen, zudem wurde die Möglichkeit für verschiedene studentische Abschlussarbeiten gegeben.

Das Datenmanagement erfolgte in Zusammenarbeit zwischen CAU, GAUG und LLH. Es wurden einheitliche Datenstrukturen geschaffen und eine Cloud-basierte Projektdatenbank eingerichtet. Die Feldexperiment-Daten wurden systematisch nach Standort, Jahr und Kategorie strukturiert, ergänzt durch Wetterdaten des DWD, und zur Bearbeitung der verschiedenen Arbeitspakete zur Verfügung gestellt.

Die Ergebnisse wurden an Stakeholder in Praxis und Wissenschaft vermittelt. Sie wurden auf verschiedenen nationalen und internationalen Tagungen präsentiert und in wissenschaftlichen Publikationen veröffentlicht. Ein Stakeholder-Workshop fand 2023 statt, während ein geplanter Workshop 2024 aufgrund zu geringer Teilnehmerzahlen abgesagt wurde. Die Ergebnisse wurden stattdessen schriftlich und in Online-Meetings diskutiert und veröffentlicht.

#### **Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais**

In den Versuchsjahren 2021 und 2022 wurden an drei Standorten Feldversuche mit drei Maissorten unterschiedlicher Reifegruppen und differenzierter N-Düngung (mineralisch und organisch) durchgeführt. Trotz Corona-bedingter Einschränkungen und schwieriger Witterungsbedingungen (Sturm 2021, Trockenheit 2022) konnten die Versuche erfolgreich angelegt und durchgeführt werden. Die Standorte wurden hinsichtlich ihrer Bodeneigenschaften charakterisiert, und die Dynamik der Spross-Trockenmassebildung wurde über fünf Beprobungstermine erfasst. An der CAU wurden zusätzlich die Aufteilung der Trockenmasse auf Pflanzenfraktionen und der Green Area Index (GAI) bestimmt. N-Gehaltsanalysen verzögerten sich, wurden jedoch 2024 abgeschlossen und an andere Arbeitspakete weitergegeben.

Die Trockenheit 2022 führte zu starken Unterschieden in den Erträgen und zur eingeschränkten Bodenbeprobung. Während die CAU aufgrund besserer Wasserversorgung höhere Erträge erzielte, zeigte sich am trockenen LLH-Standort kaum eine Ertragssteigerung durch N-Düngung. Die gravimetrische Bodenfeuchte und der Nmin-Verlauf bestätigten die standortspezifischen Unterschiede. Die Prüfung des Sorteneinflusses auf die kritische N-Funktion sowie die regressionsanalytische Ableitung von N-Optima und maximalem N-Ertrag erfolgte durch die GAUG mit Unterstützung der CAU (Datenbereitstellung, Analyse und Publikation).

## **Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais**

Im Rahmen der UAV-Befliegungen zur spektralen Erfassung der N-Aufnahme von Silomais wurde der Spektralsensor Parrot Sequoia™ auf die Bestandesparameter Green Area Index (GAI) und N-Aufnahme kalibriert. Trotz Verzögerungen bei der Technikanschaffung konnten die Befliegungen an der CAU wie geplant durchgeführt und die Spektraldaten umfassend ausgewertet werden. Die Kalibrationen ermöglichen eine hochaufgelöste zeitliche Erfassung der Bestandesparameter, jedoch ist die Erfassung der N-Aufnahme nur bis zur Blüte realisierbar.

Die zeitlich hochaufgelösten GAI- und N-Aufnahme-Verläufe konnten Sorten- und Düngevariantenunterschiede aufzeigen. UAV-basierte Thermaldaten belegten Temperaturunterschiede zwischen Düngungsvarianten und Standorten, die auf Wasserverfügbarkeit und Bodentextur hinweisen. Zusätzlich wurde die Möglichkeit geprüft, aus hochaufgelösten RGB-Daten der UAV-Befliegungen die Bestandeshöhe abzuleiten. Die Ergebnisse zeigten eine starke Korrelation mit den manuell gemessenen Pflanzhöhen und belegen die Eignung dieser Methode zur ergänzenden Bestandesanalyse.

## **Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation**

Ziel dieses Arbeitspakets war die Erstellung einer Datenbank aus Stickstoffdüngungssteigerungsversuchen in Silomais sowie deren Auswertung im Hinblick auf die Entwicklung von Regressionsmodellen zur Prognose des N-Düngeoptimums und der N-Nettomineralisation. Trotz Verzögerungen in der Datenbereitstellung durch verschiedene Landwirtschaftskammern konnten diese Ziele erreicht werden.

Die Ergebnisse zeigen eine enorme Variation der Nettomineralisation, was wiederum ein großes Potential an N-Düngeeinsparungen bietet. Neben der N-Düngung steuern vor allem die Menge und das C:N-Verhältnis der Residuen von Vor- und Zwischenfrucht die Nettomineralisation. Es konnte gezeigt werden, dass die derzeitige Düngeverordnung diese Effekte nicht ausreichend widerspiegelt.

Während der Zusammenarbeit mit den Landwirtschaftsämtern kam die Frage auf, inwiefern ein Grenzwert für das Nachernte-N<sub>min</sub> ein sinnvolles Element für einen umweltschonenden Silomaisanbau sein könnte. Dem wurde auf der Basis der zusammengestellten Datenbank in einer zusätzlichen Analyse nachgegangen. Die statistischen Analysen belegen signifikante Effekte von Bodenparametern wie Sand- und SOC-Gehalt sowie deren Wechselwirkungen mit der Jahresdurchschnittstemperatur auf den Zusammenhang von N-Düngeoptimum und N<sub>min</sub>-Erhöhung zwischen Aussaat und Ernte. Während auf schweren Böden wie Schlufftonen, Lehmschluffen und Tonschluffen sowohl ökonomische als auch ökologische Parameter im unkritischen Bereich liegen, zeigen sich insbesondere auf sandigen Standorten, vor allem Reinsanden, deutliche Herausforderungen.

## **Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation**

Die umfangreichen Bodenbeprobungen durch die GAUG wurden durch das zur Verfügung von mehreren Parzellenversuchen auf dem Versuchsgut der CAU unterstützt. Zudem beteiligte sich die GAUG im Rahmen der durch die GAUG geplanten Publikation.

## **Arbeitspaket 5: Modellgestützte Analyse, Entwicklung einer optimierten N-Strategie**

Arbeitspaket 5 befasste sich mit der modellgestützten Analyse und der Entwicklung einer optimierten N-Strategie für den Silomais. Ausgangspunkt war ein Prozessmodell, das ursprünglich in einer Dissertation an der CAU entwickelt wurde und auf den BiogasExpert-Feldversuchen basierte. Die Überarbeitung des Modells erfolgte jedoch mit Verzögerung, was teilweise auf die späte Verfügbarkeit von Versuchsdaten zurückzuführen war. Der überarbeitete Modellansatz berücksichtigt nun die N-Aufnahme auf der Basis von Organen, statt auf die Gesamtpflanze. Eine wesentliche Verbesserung war die Implementierung von N-Verdünnungskurven für die einzelnen Pflanzenteile, was die Prognose des N-Bedarfs und die Ertragsbildung weiter verfeinerte.

Bei der Modellierung wurde eine stärkere Differenzierung zwischen den Phänologien der verschiedenen Silomais-Sorten und Standorte vorgenommen. Das Modell zeigt gute Übereinstimmungen in Bezug auf die Ertragsbildung und das Trockenmassewachstum, insbesondere in den Jahren 2021 und 2022, und ist in der Lage, die Auswirkungen von Trockenstress korrekt abzubilden. Jedoch gab es auch noch Herausforderungen, insbesondere bei der Modellierung der N-Aufnahme unter N-Mangelbedingungen.

## **3. Wesentliche Ergebnisse des Teilvorhabens**

Im Rahmen des Teilvorhabens wurden deutliche Fortschritte im Hinblick auf eine besser N-Effizienz im Silomaisanbau generiert. Hierzu gehören die Möglichkeit, nun mit geringem Aufwand mit Drohnen große Mengen an zeitlich und räumlich hochaufgelösten Bestandesdaten generieren zu können. Zudem wurden wesentliche Erkenntnisse zu den Standort- und Managementeinflüssen auf die N-Dynamiken im Silomaisanbau gewonnen und an wichtige Stakeholder im Bereich der Düngeplanung kommuniziert. Das weiterentwickelte Prozessmodell zur Ertragsbildung im Silomaisanbau könnte vor dem Hintergrund zukünftiger

Klimaänderungen, neuer Sorten und veränderter N-Rahmenbedingungen ein wertvolles Tool zur Gestaltung eines nachhaltigen Silomaisanbaus in Deutschland sein.

## **Teilvorhaben 2: Bestimmung der Standort- und vorfruchtspezifischen N-Nettomineralisation durch Nutzung spektraler Informationen zur Düngungsoptimierung im Maisanbau, Georg-August-Universität Göttingen, Department für Nutzpflanzenwissenschaften, Graslandwissenschaft**

### **1. Ziel und Gegenstand des Teilvorhabens**

Übergeordnetes Ziel des Projekt NEffMais war es, zur Erhöhung der Stickstoff (N)-Nutzungseffizienz im Silomaisanbau beizutragen. Der Fokus der Arbeiten lag hierbei in der Erfassung, Modellierung und Prognose der Ertragsbildung und N-Dynamik im Silomaisanbau. Ziel des GAUG-Teilvorhabens war hierbei in AP1 i) die Bereitstellung von Silomaisbeständen unterschiedlicher Sorten mit differierender N-Versorgung an drei Standorten für weitere Untersuchungen, ii) die Prüfung des Sorteneinflusses auf die kritische N-Funktion und iii) eine regressionsanalytische Analyse und Ableitung von N-Optima und maximalem N-Ertrag der Sorten. In AP4 waren die Ziele i) die Bestimmung der Nettomineralisation an einem großen, repräsentativen Set von Bodenmonolithen, ii) die Entwicklung eines NIRS-basierten Schätzmodelles für die potentielle Nettomineralisation und iii) die Validierung des Schätzmodelles an unabhängigen Daten. Grundlage für diese Arbeiten bildeten umfangreiche Feldversuche der drei Projektpartner an drei Standorten und zwei Jahren. Der GAUG oblag die federführende Durchführung und Analyse der Feldversuchsdaten hinsichtlich der N-Effizienz und die Auswertung der N-Konzentrationen der Biomasse durch Nutzung von NIRS und Elementaranalyse. In AP4 war die GAUG für die Planung, Umsetzung und Analyse der Arbeiten verantwortlich.

### **2. Bearbeitete Arbeitspakete**

#### **Arbeitspaket 0: Projektkoordination**

Die Projektkoordination wurde von der CAU Kiel übernommen. Projekttreffen fanden regelmäßig online statt, während Präsenztreffen in Wehnen (2021) und Hohenschulen (2022) sowie ein Stakeholder-Workshop (2023) abgehalten wurden. Ein geplanter Workshop 2024 wurde aufgrund zu geringer Teilnehmerzahlen abgesagt. Die Ergebnisse wurden stattdessen schriftlich und in Online-Meetings diskutiert und veröffentlicht. Im Rahmen der Feldversuche entstanden/entstehen (Stand März 2025) mehrere wissenschaftliche Publikationen, zudem wurde die Möglichkeit für verschiedene studentische Abschlussarbeiten gegeben.

Das Datenmanagement erfolgte in Zusammenarbeit zwischen CAU, GAUG und LLH. Es wurden einheitliche Datenstrukturen geschaffen und eine Cloud-basierte Projektdatenbank eingerichtet. Die Feldexperiment-Daten wurden systematisch nach Standort, Jahr und Kategorie strukturiert, ergänzt durch Wetterdaten des DWD, und zur Bearbeitung der verschiedenen Arbeitspakete zur Verfügung gestellt.

Die Ergebnisse wurden an Stakeholder in Praxis und Wissenschaft vermittelt (siehe Publikationsliste). Sie wurden auf verschiedenen nationalen und internationalen Tagungen präsentiert und in wissenschaftlichen Publikationen veröffentlicht.

#### **Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais**

In den Versuchsjahren 2021 und 2022 wurden an drei Standorten Feldversuche mit drei Maissorten unterschiedlicher Reifegruppen und differenzierter N-Düngung (mineralisch und organisch) durchgeführt. Trotz Corona-bedingter Einschränkungen und schwieriger Witterungsbedingungen (Sturm 2021, Trockenheit 2022) konnten die Versuche erfolgreich angelegt und durchgeführt werden. Die Standorte wurden hinsichtlich ihrer Bodeneigenschaften charakterisiert, und die Dynamik der Spross-Trockenmassebildung wurde über fünf bis sechs Beprobungstermine erfasst. Die GAUG hat am Standort in Bad Hersfeld zusätzlich die Aufteilung der Trockenmasse auf Pflanzenfraktionen und den Green Area Index (GAI) bestimmt. Alle Biomasseproben wurden mittels NIRS und Elementaranalyse zur Bestimmung der N-Gehalte untersucht. Die N-Gehaltsanalysen verzögerten sich, wurden jedoch 2024 abgeschlossen und an andere Arbeitspakete weitergegeben. Die Trockenheit 2022 führte zu starken Unterschieden in den Erträgen und zur eingeschränkten Bodenbeprobung. Während die CAU aufgrund besserer Wasserversorgung höhere Erträge erzielte, zeigte sich am trockenen LLH-Standort kaum eine Ertragssteigerung durch N-Düngung. Die gravimetrische Bodenfeuchte und der Nmin-Verlauf bestätigten die standortspezifischen Unterschiede. Die Prüfung des Sorteneinflusses auf die kritische N-Funktion sowie die regressionsanalytische Ableitung von N-Optima und maximalem N-Ertrag erfolgte durch die GAUG mit Unterstützung der CAU (Datenbereitstellung, Analyse und Publikation).

#### **Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais**

Im Rahmen der UAV-Befliegungen zur spektralen Erfassung der N-Aufnahme von Silomais wurde der Spektrolsensor Parrot Sequoia™ auf die Bestandesparameter Green Area Index (GAI) und N-Aufnahme durch die CAU kalibriert. Trotz Verzögerungen bei der Technikanschaffung konnten die Befliegungen durch die

GAUG durchgeführt werden. Die Kalibrationen ermöglichen eine hochaufgelöste zeitliche Erfassung der Bestandesparameter, jedoch ist die Erfassung der N-Aufnahme nur bis zur Blüte realisierbar.

### **Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation**

Es wurden archivierte Feldversuchsdaten an die CAU zur Auswertung übergeben. Die GAUG beteiligte sich an Diskussion und Workshops sowie im Rahmen der Publikationen.

### **Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation**

Es wurden mehrortig ungestörte Bodenproben in den Wintermonaten 2021/2022 und 2022/2023 in einer Bodentiefe von 10-25 cm erhoben. Diese wurden anschließend dunkel und aerob bei ca. 17-18°C inkubiert. Die N-Mineralisation in diesen ungestörten Bodenproben wurden durch Analyse der Nmin-Gehalte zu T0 und nach 100 Tagen (T1) berechnet. In jeder Probe wurden laboranalytische Kenngrößen der Korngrößenverteilung, der Bodennährstoffgehalte sowie alle Informationen zur Düngung und zur Fruchtfolge der Standorte zusammengeführt. Die gemessene N-Nachlieferung in den Bodenproben zwischen T0 und T1 war insgesamt gering. Die Bodenproben wurden mittels NIRS gemessen, um Spektraldaten zu erhalten. Mithilfe dieser Datenbasis wurden unterschiedliche Machine-Learning (ML) Modelle trainiert. Die Kalibration und Validation der ML-Modelle waren in Grenzen vielversprechend. Zusätzlich wurden Bodenproben in allen Parzellenversuchen von WP1 zur Analyse gewonnen. Diese Proben wurden zur unabhängigen Validation genutzt. Die Validation ergab keine gute Übereinstimmung mit den Schätzmodellen basierend auf Inkubationen. Gründe hierfür sind die in der Inkubation gesetzten Konditionen (aerob, feucht ca. 84% Wasser, keine Temperaturvariation, keine wachsenden Maispflanzen). Diese Bedingungen sind im Vergleich zur Situation im Feld, wo Pflanzenbestände die N-Dynamik in der Rhizosphäre beeinflussen.

## **3. Wesentliche Ergebnisse des Teilvorhabens**

Im Rahmen des Teilvorhabens wurden deutliche Fortschritte im Hinblick auf eine bessere N-Effizienz im Silomaisanbau generiert. Hierbei ist insbesondere zu betonen, dass ein besseres Verständnis darüber besteht, dass die kritische N-Verdünnungsfunktion nicht zwischen Sorten variiert. Die Ergebnisse erlauben darüber hinaus ein besseres Verständnis darüber, dass sich aufgrund der Reifegruppe der Sorten keine Unterschiede in der N-Düngungshöhe ergeben. Das Projekt liefert darüber hinaus Schlüsse darüber wie sich die N-Effizienz aufgrund der Witterung verändert. Bisherige Studien zeigen, dass im Trockenjahr generell mit einer Verschlechterung der N-Effizienz zu rechnen ist. Wir können aufgrund der sehr stark kontrastierenden Umweltbedingungen zwischen 2021 und 2022, insbesondere aufgrund des sehr stark N-nachliefernden Standortes in Wehnen, zeigen, dass die N-Effizienz im Trockenjahr steigt, wenn die N-Verfügbarkeit im Boden stärker zurückgeht als die Erträge. Folgendes Beispiel verdeutlicht den Effekt: Die Niederschlagsmenge in Wehnen war im Vergleich zur Langzeitwitterung in 2021 37% höher und in 2022 22% geringer. Die N-Verfügbarkeit (Nav) aufgrund der N-Mineralisation + N-Düngung + N-Aufnahme in der ungedüngten Variante ist von 2021 auf 2022 im Mittel über alle Varianten um 52% zurückgegangen. Der Ertrag ist um 31% zurückgegangen. Aufgrund der relativ schwächeren Ertragsreduktion und aufgrund der starken Trockenheitsreaktion der Nav im Boden, war die N-Effizienz mit 50 vs. 97 kg TM kg<sup>-1</sup> Nav im feuchten Jahr 2021 geringer als im Trockenjahr 2022. Am Standort in Bad Hersfeld war die N-Effizienz dagegen im feuchten Jahr 2021 höher als im Trockenjahr 2022 (83 vs. 65 kg TM kg<sup>-1</sup> Nav). Dies geht auf eine stärkere relative Abnahme des Ertrages (-51%) im Vergleich zur kleineren relativen Abnahme der Nav (-27%) zurück. Die Vorhersage der N-Mineralisation des Bodens, mittels aus NIRS generierten Spektraldaten, ist für unter standardisierten Bedingungen gewonnene Bodenbedingungen durch Nutzung von Machine Learning in der Datenanalyse in Grenzen möglich.

## **Teilvorhaben 3: Bestimmung genotypbedingter Variabilität der kritischen N-Funktion und Ableitung der optimalen N-Düngung im Maisanbau**

### **1. Ziel und Gegenstand des Teilvorhabens**

Übergeordnetes Ziel des Projekt NEffMais war es, zur Erhöhung der Stickstoff (N)-Nutzungseffizienz im Silomaisanbau beizutragen. Der Fokus der Arbeiten lag hierbei in der Erfassung, Modellierung und Prognose der Ertragsbildung und N-Dynamik im Silomaisanbau. Ziel des LLH-Teilvorhabens war hierbei die Prüfung des Sorteneinflusses auf die kritische N-Funktion und iii) eine regressionsanalytische Analyse und Ableitung von N-Optima und maximalem N-Ertrag der Sorten. In WP4 bestanden die Ziele in der Bestimmung der N-Nettomineralisation an einem großen, repräsentativen Set von Bodenmonolithen und hierfür die Durchführung von Bodeninkubationen. Grundlage für diese Arbeiten bildeten umfangreiche Feldversuche der drei Projektpartner an drei Standorten und zwei Jahren. Dem LLH oblag die federführende Durchführung der Laborinkubation sowie die Bereitstellung der Feldversuchsdaten für AP3 und AP4.

## **2. Bearbeitete Arbeitspakete**

### **Arbeitspaket 0: Projektkoordination**

Das Datenmanagement erfolgte in Zusammenarbeit zwischen CAU, GAUG und LLH. Es wurden einheitliche Datenstrukturen geschaffen und eine Cloud-basierte Projektdatenbank eingerichtet. Die Feldexperiment-Daten wurden systematisch nach Standort, Jahr und Kategorie strukturiert, ergänzt durch Wetterdaten des DWD, und zur Bearbeitung der verschiedenen Arbeitspakete zur Verfügung gestellt. Die Ergebnisse wurden an Stakeholder in Praxis und Wissenschaft vermittelt (siehe Publikationsliste). Sie wurden auf verschiedenen nationalen und internationalen Tagungen präsentiert und in wissenschaftlichen Publikationen veröffentlicht.

### **Arbeitspaket 1: Ermittlung genotypbedingter Differenzen der N-Effizienz von Silomais**

In den Versuchsjahren 2021 und 2022 wurden an drei Standorten Feldversuche mit drei Maissorten unterschiedlicher Reifegruppen und differenzierter N-Düngung (mineralisch und organisch) durchgeführt. Trotz Corona-bedingter Einschränkungen und schwieriger Witterungsbedingungen (Sturm 2021, Trockenheit 2022) konnten die Versuche erfolgreich angelegt und durchgeführt werden. Die Standorte wurden hinsichtlich ihrer Bodeneigenschaften charakterisiert, und die Dynamik der Spross-Trockenmassebildung wurde über fünf bis sechs Beprobungstermine erfasst. Der LLH hat am Standort in Bad Hersfeld zusätzlich die Aufteilung der Trockenmasse auf Pflanzenfraktionen und den Green Area Index (GAI) bestimmt. Die Trockenheit 2022 führte zu starken Unterschieden in den Erträgen und zur einer eingeschränkten Bodenbeprobung. Am trockenen LLH-Standort zeigte sich keine Ertragssteigerung durch N-Düngung. Optimale N-Düngungshöhen konnten aufgrund der stark divergierenden Witterungsbedingungen zwischen den Jahren für die einzelnen Standorte nicht zuverlässig ermittelt werden. Geprüft wurden quadratische Regressionen und Linear-Plateau-Ansätze. Die gravimetrische Bodenfeuchte und der Nmin-Verlauf bestätigten die standortspezifischen Unterschiede.

### **Arbeitspaket 2: Spektrale, UAV-gestützte Erfassung der N-Aufnahme von Silomais**

Im Rahmen der UAV-Befliegungen zur spektralen Erfassung der N-Aufnahme von Silomais wurde der Spektroskop Parrot Sequoia™ auf die Bestandesparameter Green Area Index (GAI) und N-Aufnahme durch die CAU kalibriert. Trotz Verzögerungen bei der Technikanschaffung konnten die Befliegungen durch den LLH durchgeführt werden. Die Kalibrationen ermöglichen eine hochaufgelöste zeitliche Erfassung der Bestandesparameter, jedoch ist die Erfassung der N-Aufnahme nur bis zur Blüte realisierbar.

### **Arbeitspaket 3: Regressionsmodellierung von Stickstoffdüngungsoptimum und N-Mineralisation**

Es wurden archivierte Feldversuchsdaten an die CAU zur Auswertung übergeben. Der LLH beteiligte sich an Diskussionen und Workshops sowie im Rahmen der Publikationen. Der LLH war zu großen Teilen für die wissenschaftliche Datenaufbereitung zuständig. Die Ergebnisse zeigen eine enorme Variation der Nettomineralisation, was wiederum ein großes Potential an N-Düngeersparungen bietet. Neben der N-Düngung steuern vor allem die Menge und das C:N-Verhältnis der Residuen von Vor- und Zwischenfrucht die Nettomineralisation. Es konnte gezeigt werden, dass die derzeitige Düngeverordnung diese Effekte nicht ausreichend widerspiegelt.

### **Arbeitspaket 4: NIRS-gestützte Modellierung der N-Mineralisation**

Der LLH hat die Inkubationen in AP4 maßgeblich durchgeführt, technisch kontrolliert und Daten dafür aufgenommen. Im Mittel ergaben sich geringe mittlere Mineralisationsmengen, was intensiv diskutiert wurde.

## **3. Wesentliche Ergebnisse des Teilvorhabens**

Im Rahmen des Teilvorhabens wurden deutliche Fortschritte im Hinblick auf eine bessere N-Effizienz im Silomaisanbau generiert. Hierbei ist insbesondere zu betonen, dass ein besseres Verständnis darüber besteht, dass die kritische N-Verdünnungsfunktion nicht zwischen Sorten variiert. Die Ergebnisse erlauben darüber hinaus ein besseres Verständnis darüber, dass sich aufgrund der Reifegruppe der Sorten keine Unterschiede in der N-Düngungshöhe ergeben. Allerdings konnte aufgrund der Witterungsbedingungen und der standörtlichen N-Nachlieferung keine optimale N-Düngung ermittelt werden.