

Detektion von Pflanzenstress in hyperspektralen Bildern im Nahbereich

JAN BEHMANN¹, PETER SCHMITTER¹, JÖRG STEINRÜCKEN¹, AGIM BALLVORA², ANNE-KATRIN MAHLEIN³ & LUTZ PLÜMER¹

Zusammenfassung: Der Umgang mit Pflanzenstress ist entscheidend für die landwirtschaftliche Nahrungsmittelproduktion, da betroffene Pflanzen unter Stresseinfluss nicht ihr gesamtes genetisches Ertragspotential ausschöpfen können. Bei einer frühzeitigen Detektion des Stresses und einer Identifikation der Ursache kann der auslösende Faktor effektiv in Bezug auf Ressourceneinsatz und Umweltbelastung bekämpft werden. Für die Züchtung liefert die Bestimmung der Stressresistenz, als Teil der Phänotypisierung, wichtige Informationen für die Auswahl vielversprechender Genotypen. Hyperspektrale Kameras sind dabei ein wichtiger Sensortyp der sowohl den sichtbaren Bereich als auch Teile des infraroten Spektrums aufzeichnet. Die Analyse der hyperspektralen Nahbereichs-Bilder erfordert jedoch fortgeschrittene Methoden der Dateninterpretation. In dieser Arbeit werden die Grundlagen der Stressdetektion mit hyperspektralen Kameras vorgestellt und Datenanalysemethoden der Fernerkundung und des maschinellen Lernen anhand konkreter Anwendungen diskutiert.

1 Einleitung

Pflanzen können ihr genetisches Ertragspotential nur unter idealen Wachstumsbedingungen ausschöpfen (GASPAR et al. 2002). Abweichungen von idealen Bedingungen, die eine von den Pflanzen tolerierbare Intensität und Dauer überschreiten, induzieren Stress (TAIZ & ZEIGER 2010). Stressoren können sowohl abiotisch (z.B. Dürre und Hitze) als auch biotisch (z.B. bakterielle Infektionen und Pilzbefall) sein. Eine effektive Bekämpfung des Stressors bzw. eine Einschränkung des Stressprozesses erfordert frühzeitig detaillierte Informationen über Ausmaß und den auslösenden Faktor des Stresses. Von großer Bedeutung ist die Detektion und Identifikation von Stress auch für die Züchtung, wo im Rahmen der Phänotypisierung, die Bestimmung der Stressresistenz wichtige Informationen für die Entwicklung von Pflanzensorten mit hohem Ertragspotential auch unter schwierigen Umweltbedingungen liefert (FURBANK & TESTER 2011).

In den letzten Jahren wird im Bereich der Präzisionslandwirtschaft der Zustand von Nutzpflanzen verstärkt durch optische Sensoren im Nahbereich überwacht (BEHMANN et al. 2014b). Derartige Sensoren werden sowohl in stationären Szenarien als auch auf mobilen Plattformen eingesetzt. Als mobile Plattformen können Schleppanhänger oder UAVs (*unmanned*

¹ Institut für Geodäsie und Geoinformation, Universität Bonn, Meckenheimer Allee 172, 53115 Bonn; E-Mail: behmann@igg.uni-bonn.de

² Institut für Nutzpflanzenwissenschaften und Ressourcenschutz, Professur für Pflanzenzüchtung, Katzenburgweg 5, 53115 Bonn

³ Institut für Nutzpflanzenwissenschaften und Ressourcenschutz, Professur für Pflanzenkrankheiten und Pflanzenschutz, Meckenheimer Allee 166a, 53115 Bonn

aerial vehicle) mit einem starken Fokus auf leichtgewichtige Sensor-, Steuerungs- und Speichertechnik genutzt werden (BARETH et al. 2015).

Ein spezifischer Sensortyp fürs Pflanzenmonitoring sind hyperspektrale Kameras, die die spektralen Reflektanzeigenschaften von Pflanzenoberflächen auch über den sichtbaren Wellenlängenbereich hinaus messen. Diese Beobachtungen müssen zu Zielgrößen wie Krankheitsbefall bzw. Stresszustand in Relation gesetzt werden, um eine zielführende Interpretationen der Sensordaten zu ermöglichen.

In dieser Arbeit wird die Anwendung und Anpassung von Methoden der Fernerkundung für die Analyse hyperspektraler Daten im Nahbereich diskutiert. Hyperspektrale Aufnahmen im Nahbereich verfügen im Gegensatz zu Luft- und Satellitenaufnahmen über eine höhere Varianz, da die einzelnen Pixel nicht über einen größeren Bereich der beobachteten Oberfläche integrieren. Im Nahbereich werden einzelne Blätter mit ihren individuellen Winkeln, Verschattungen und geometrischen Strukturen sichtbar (BEHMANN et al. 2014a), wohingegen in einem Luftbild häufig die gesamte Pflanze durch einen Pixel repräsentiert wird.

Eine Analysemethode aus der Fernerkundung sind Vegetationsindizes (VIs), die Änderungen im Spektrum mit pflanzen-physiologischen Adaptionen in der Pigmentzusammensetzung oder Zellstruktur in Verbindung bringen (JENSEN 2009). Vegetationsindizes werden bereits seit Jahrzehnten erfolgreich bei der Auswertung von multi- und hyperspektralen Luft- und Satellitenbildern eingesetzt. In jüngster Zeit werden auch verstärkt die Reflektanzen in den einzelnen Bändern oder eine selektierte Untermenge dieser Einzelbänder direkt analysiert.

Die Auswertung der resultierenden, kompakteren Darstellung durch die genannten Merkmale, unabhängig davon ob VIs oder direkt beobachtete Spektralbänder, erfordert häufig Methoden des *Maschinellen Lernens* (BREIMAN 2001). Methoden des Maschinellen Lernens haben in der Fernerkundung überlegene Prädiktionsgenauigkeiten im Vergleich zu rein verteilungsbasierten Modellen oder schwellwertbasierten Klassifikationsmethoden gezeigt. Diese Verfahren sind auch im Nahbereich erforderlich um zielgerichtet die Informationen einer Vielzahl von Merkmalen effektiv in Prädiktionsmodellen zu bündeln und vom Stress befallene Pflanzen oder Pflanzenteile zu detektieren. Darüber hinaus spielt die Auswertung der räumlichen Verteilung der Stresssymptome für die Ergebnishüte eine große Rolle. In diesem Feld gibt es bisher jedoch nur wenige Vorarbeiten.

2 Sensorsysteme

Die Sensorsysteme setzen sich aus Trägersystem und hyperspektraler Kamera zusammen, wobei je nach Anwendungsszenario – Laborbedingungen oder Freiland - stationäre oder mobile Trägerplattformen zum Einsatz kommen. Die Kameratechnik ist dabei der Art der Trägerplattform anzupassen, da diese verschiedene Limitierungen mit sich bringen.

2.1 Trägersysteme

2.1.1 Stationäre Systeme

Ein Großteil der zum Pflanzenmonitoring eingesetzten hyperspektralen Sensoren wird zurzeit in kleineren Forschungssystemen eingesetzt (z.B. BEHMANN et al., 2014a, Abb. 1). Im Rahmen

einer bestimmten Fragestellung (z. B. „Wie entwickelt sich eine Pflanze mit reduzierter Bewässerung im Vergleich zu einer optimal bewässerten Pflanze“) werden einzelne oder eine begrenzte Anzahl von Pflanzen beobachtet.

In einem größeren Rahmen werden aktuell an mehreren Standorten weltweit Phänotypisierungsplattformen errichtet. Diese Anlagen haben die Verknüpfung des pflanzlichen Genotyps mit phänotypischen Merkmalen zum Ziel und sind als Hochdurchsatz-Anlagen konzipiert. Sie tragen der Tatsache Rechnung, dass geringste Unterschiede in den äußeren Bedingungen deutliche Unterschiede in den phänotypischen Merkmalen hervorrufen können (CABRERA-BOSQUET et al. 2012) und messen für eine belastbare und statistisch signifikante Analyse der phänotypischen Merkmale einen großen Stichprobenumfang. Dazu werden innerhalb eines Experiments hunderte oder sogar tausende Pflanzen unter weitgehend kontrollierten Bedingungen im Gewächshaus herangezogen und automatisiert beleuchtet, bewässert, bewegt und vermessen (FURBANK & TESTER 2011, CABRERA-BOSQUET et al. 2012). Die Relevanz von Analyseverfahren zur Auswertung der aufgezeichneten, enormen Datenmengen steigt gerade in diesen Anlagen drastisch.

Die zugrundeliegende Sensortechnik ist bei allen stationären Systemen häufig vergleichbar. Mit hoher Auflösung werden in einem speziellen Messraum oder an einem Messplatz unter kontrollierten Umweltbedingungen die Reflektanzeigenschaften von unbewegten Pflanzen aufgezeichnet.




Abb. 1: Sensorsysteme mit hyperspektralen Kameras. Im linken Teil ist ein Laborsystem bestehend aus zwei hyperspektralen Zeilenkameras (VISNIR & SWIR) zu sehen (BEHMANN et al. 2014a) und rechts ein UAV mit einer geeigneten Hyperspektralkamera die zeitgleich alle Pixel eines Bildes aufnimmt (BARETH et al. 2015).

2.1.2 Mobile Systeme

Bei der Übertragung der hyperspektralen Sensorik auf Anwendungen im Feld kommen hingegen mobile Systeme mit Traktoren oder Sensorwagen als Trägerplattform zum Einsatz. Diese besitzen den Vorteil, dass sie große Flächen in kurzer Zeit im Freiland befahren können. Da Züchtungsversuche im Freiland statt im Gewächshaus deutlich wirtschaftlicher sind, stellen diese den Normalfall dar und sind alternativlos um der natürlichen Variabilität der Pflanzen zu begegnen.

Eine erfolgsversprechende Alternative zu den fahrenden Trägerplattformen sind UAVs (*unmanned aerial vehicle*). Diese fliegenden Plattformen sind in der Lage in kürzester Zeit auch große Felder zu vermessen ohne das Ergebnis des Versuchs durch Befahrungen zu beeinflussen (BARETH et al. 2015, Abb. 1).

Aufnahmen von fahrenden Plattformen sind in der Regel von deutlich geringerer Qualität, da sowohl die Umweltbedingungen während der Messung nicht so gut kontrollierbar sind und zusätzliche Effekte durch die Bewegungsunschärfe hinzukommen. Aufgrund der grundsätzlich reduzierten Qualität der Daten werden hier häufig Sensoren mit geringer räumlicher Auflösung eingesetzt. Beim Großteil der Versuche kommen sogar ausschließlich Punktsensoren zum Einsatz (ERDLE et al. 2011), die eine Aussage über einen gewissen Bereich der angelegten Kultur ermöglichen.

2.2 Kameratechnik

Hyperspektrale Kameras werden neben der Geologie, den Materialwissenschaften und der Fernerkundung auch fürs Pflanzenmonitoring eingesetzt. Hier bestimmen sie die Reflektanzeigenschaften von Pflanzenoberflächen in einer Vielzahl von Wellenlängen und an einer Vielzahl von räumlichen Pixelpositionen. Der spektrale Messbereich umfasst in der Regel das sichtbare Spektrum und den nahen und mittleren Infrarotbereich. Im Nahbereich werden die Reflektanzspektren einzelner Blätter und sogar hochaufgelöste Strukturen innerhalb eines Blattes beobachtet.

Die verbreitetste Sensortechnik bei hyperspektralen Kameras ist die Zeilenkamera, wobei an einem schmalen Spalt das einfallende Licht aufgespalten und auf das photosensitive Sensorarray projiziert wird (GRIETENS 2008). Die Position eines Pixels innerhalb des Arrays ist durch eine spektrale Dimension (beobachtete Wellenlänge) und eine räumliche Dimension (Pixel der beobachteten Linie) definiert. Ein hyperspektrales Bild mit zwei räumlichen Dimensionen entsteht dann durch eine lineare Bewegung der Kamera oder des Objekts oder durch eine Umlenkung der beobachteten Zeile mittels eines beweglichen Spiegel.

Die Limitierungen der Zeilenkamera durch die notwendige Verknüpfung der einzelnen Pixelzeilen insbesondere in dynamischen Szenarien haben zu der Entwicklung von Kameras geführt, die in der Lage sind, die spektralen Information eines gesamten Bildes in einem Schritt aufzunehmen. Derartige Systeme sind jedoch im Vergleich zu den Zeilenkameras in der Anzahl der Pixel stark limitiert, eignen sich jedoch insbesondere für fliegende Plattformen (BARETH et al., 2015). Im Rahmen des technologischen Fortschritts ist eine Erhöhung der räumlichen Auflösung derartiger Sensoren in den nächsten Jahren zu erwarten.

3 Stressdetektion in spektralen Beobachtungen

Das Reflektanzspektrum von Pflanzen im sichtbaren Bereich des Spektrums und nahem Infrarot enthält hauptsächlich Informationen über die Blattpigmente und die Zellstruktur des Blattes. Das bekannteste Pigment ist das Chlorophyll, das im sichtbaren Spektralbereich dominant ist und für die grüne Farbe der Blätter sorgt. Die Absorptionsbereiche von Chlorophyll liegen im blauen und im roten Spektralbereich wodurch Licht im grünen Spektralbereich in Relation verstärkt reflektiert wird.

Die Interpretation der aufgezeichneten hyperspektralen Bilder ist herausfordernd. Einerseits erfordern die großen Datenmengen effiziente Algorithmen, andererseits lässt die Fragestellung häufig keine einfachen Entscheidungen zu. Hier existieren, bspw. im Gegensatz zur Klassifikation der Landflächenbedeckung aus der Fernerkundung, häufig keine diskreten, klar

definierten Klassen, sondern eine große Anzahl kontinuierlicher Übergänge, die eine Differenzierung von betroffenen und vitalen Bereichen der Pflanze erschweren (BEHMANN et al. 2014d, Abb. 2). Darüber hinaus behindern die statistischen Eigenschaften der aufgezeichneten Signale eine verlässliche Analyse. So werden zwar viele Spektralbänder gemessen, diese basieren jedoch auf einer deutlich geringeren Anzahl an häufig unbekanntem, sich im Signal überlappenden Faktoren, wie z.B. den Konzentrationen der einzelnen Blattpigmente. Die einzelnen Wellenlängen sind daher nicht unabhängig voneinander, sondern hochgradig redundant.

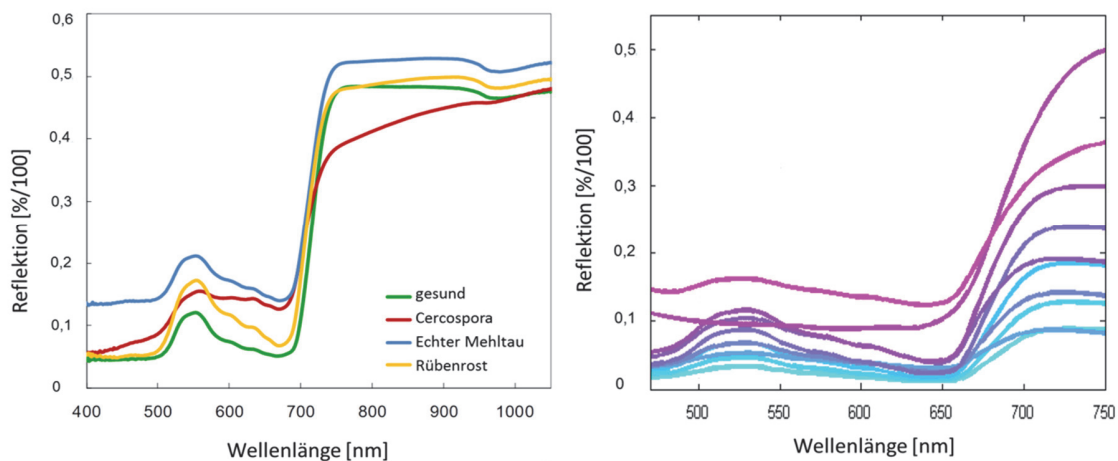


Abb. 2: Auswirkungen von Pflanzenstress auf das beobachtete Spektrum. Im linken Teil die Auswirkungen von drei Pflanzenkrankheiten und im rechten Teil der durch Trockenheit hervorgerufene kontinuierliche Stressprozess bei Gerste (blau-gesund nach lila-abgestorben)

Viele Stressprozesse sind jedoch in ihrer Auswirkung auf das Spektrum und ihrer Bedeutung bekannt (TAIZ & ZEIGER 2011). Die Einbringung derartiger Vorinformationen ist daher geeignet die Prädiktionsgüte bzw. die Interpretierbarkeit der Ergebnisse signifikant zu erhöhen. Ein derartiger Ansatz sind Vegetationsindizes (VIs), die Änderungen im Spektrum mit pflanzenphysiologischen Adaptionen in der Pigmentzusammensetzung oder Zellstruktur in Verbindung bringen (JENSEN 2009). Üblicherweise werden die VI-Werte durch Schwellwerte oder Regressionsfunktionen linearer und nicht-linearer Form ausgewertet. Sie werden bereits seit Jahrzehnten erfolgreich bei der Auswertung von multi- und hyperspektralen Luft- und Satellitenbildern eingesetzt, basieren in der Regel jedoch auf der Information aus maximal zwei bis drei Wellenlängen und können daher nicht die Informationsvielfalt des gesamten beobachteten Spektrums abbilden.

Da die Zusammensetzung des spektralen Signals Ergebnis einer großen Anzahl von Einflussfaktoren ist, eignen sich insbesondere Methoden des Maschinellen Lernens für die Interpretation. Methoden des Maschinellen Lernens machen im Gegensatz zu den klassischen Analyseverfahren weniger Annahmen über die statistischen Eigenschaften der Daten oder des enthaltenen Rauschens (BREIMANN 2001). In der Fernerkundung werden derartige Verfahren bereits seit Jahren erfolgreich, z.B. für die Landbedeckungsklassifikation eingesetzt. Bei der Stressdetektion bei Nutzpflanzen im Nahbereich werden sie erst in jüngster Zeit verstärkt eingesetzt. Die hier am häufigsten eingesetzten Algorithmen sind Support Vector Machines,

Neuronale Netze und Cluster-Algorithmen wie k-Means. Ein ausführlicher Überblick wird in BEHMANN et al. (2014b) gegeben.

Ein Ansatz um das Expertenwissen, das in die Erstellung der VI eingebracht wurde, zu nutzen aber die Qualität des Ergebnisses nicht durch eine zu geringe Anzahl ausgewerteter Wellenlängen zu limitieren, ist die Kombination von VI. Durch Methoden des maschinellen Lernens wie multivariater Regression oder Klassifikation können die Informationen mehrerer VI für eine aussagekräftigere Prädiktion kombiniert werden. Da es eine große Anzahl publizierter VI gibt, die jeweils für einen spezifischen Anwendungsfall entwickelt wurden, spielt die Selektion der relevanten VI eine große Rolle. Spezielle Merkmalsselektionsalgorithmen sind in der Lage performant aus einer großen Anzahl von Merkmalen die relevantesten auszuwählen. Die erfolgreiche Anwendung von Filter- und Wrapper-Ansätzen zu Merkmalsselektion für die Stresserkennung konnte bereits demonstriert werden (z.B. MAHLEIN et al. 2013). Es konnte gezeigt werden das die Kombination mehrerer VI deutliche Vorteile gegenüber der Analyse einzelner VI bietet (RUMPF et al. 2010, BEHMANN et al. 2014d) und das die spezifische Merkmalsselektion in Hinblick auf eine individuelle Problemstellung für die Qualität der Ergebnisse von außerordentlicher Bedeutung ist. Sollte eine zu große Anzahl von Merkmalen gewählt werden liefern viele Merkmale redundante Informationen, wodurch die Prädiktionsqualität reduziert wird.

Für spezifische Stressarten wurden angepasste Methoden entwickelt, die Vorwissen über die Auswirkungen aufs Spektrum einbezogen haben. Ein Ansatz für die Detektion spezifischer, bekannter Pflanzenkrankheiten liegt in der Entwicklung angepasster Vegetationsindizes für die enthaltenen Pflanzenkrankheiten (MAHLEIN et al. 2013). Die Formeln der verbreitetsten VI folgen bestimmten Mustern um den Einfluss von Störgrößen wie z.B. Helligkeitsunterschieden zu reduzieren. In einem kombinatorischen Verfahren, in dem die Komplexität durch eine Relevanzbetrachtung der einzelnen spektralen Bereiche signifikant reduziert wird, werden die optimale Wellenlängen der in die Indexformel eingehenden Faktoren bestimmt. Die auf diese Weise gewonnenen Indexformeln sind dann spezifisch für einzelne Krankheiten (Abb. 2, links) oder dienen der Abgrenzung von gesunden und befallenen Blatteilen.

Auch bei Trockenstress existiert Vorwissen über die Auswirkungen eines kontinuierlich fortschreitenden Stresses auf das beobachtete Reflektanzspektrum. Der Abbau der Pigmente, insbesondere des Chlorophylls, sorgt für einen kontinuierlichen Übergang (von gesund nach abgestorben) der in Abbildung 2 (rechts) diskretisiert dargestellt ist. Dieses Vorwissen kann genutzt werden um ein angepasstes Klassifikationsmodell auszuwählen. Durch die sichtbare ordinale Ordnung der Stresstadien im Merkmalsraum eignet sich insbesondere die ordinale Klassifikation für die Beschreibung und Prädiktion des zugrundeliegenden Stressprozesses (BEHMANN et al. 2014d). Derartige Verfahren haben deutliche Performancevorteile gegenüber Verfahren, die nicht auf Vorwissen basieren, da sie Informationen, die laut Vorwissen nicht benötigt werden, auch nicht aus den Daten herleiten (BEHMANN et al. 2014c).

Ein weiterer Ansatz im Bereich des Trockenstresses nutzt die gesamte Information des beobachteten Spektrums. RÖMER et al. (2012) haben ein Archetypen-Verfahren für die frühzeitige Detektion von Trockenstress verwendet. Derartige Ansätze selektieren besonders repräsentative oder relevante Spektren, die zur Rekonstruktion des gesamten Datensatzes mit geringem Informationsverlust genutzt werden können. Für die Auswertung von hyperspektralen

Nahbereichsbildern wurden sie genutzt, um den Übergang von einer gesunden zu einer Pflanze mit starken Trockenstresssymptomen zu beschreiben. Zu diesem Zweck wird eine geringe Anzahl an Archetypen, basierend auf Vorwissen über die Bedeutung der charakteristischen spektralen Signaturen, der Klasse gesund bzw. gestresst zugeordnet. Diese Zuordnung wird durch Auswertung der Distanzen im Merkmalsraum auf alle Pixel der Pflanze übertragen (RÖMER et al. 2012). Auf diese Weise kann das vorhandene Expertenwissen in moderne Verfahren des Maschinellen Lernens eingebracht und zur performanten Prädiktion von Pflanzenstress genutzt werden.

4 Räumliche Detektion von Pflanzenstress

Da hyperspektrale Kameras die spektralen Reflektanzinformationen an einer großen Anzahl von räumlichen Pixeln beobachten, ist eine geeignete Strategie zur Auswertung dieser räumlichen Information erforderlich. Pflanzenstresssymptome entwickeln sich, unabhängig vom Stressor, nicht gleichmäßig innerhalb der Pflanze. Biotischer Pflanzenstress wird hervorgerufen durch Krankheitserreger, Pilze oder Insektenbefall und prägt sich in spezifischen Symptomen aus (MAHLEIN et al. 2013). Abiotischer Pflanzenstress, zum Beispiel hervorgerufen durch Wassermangel, ist ein aktiv kontrollierter biologischer Prozess der Pflanze, durch den die Pflanze versucht ihre Reproduktionsreife zu erreichen. Dabei werden die verbliebenen Ressourcen gezielt in die Pflanzenbereiche transportiert, die bessere Voraussetzungen besitzen (BEHMANN et al. 2014d, Abb. 3).




Abb. 3: Zeitlicher Verlauf eines fortschreitenden Trockenstresses bei Gerste (blau-vital zu rot-gestresst). Sichtbar wird die ungleichmäßige räumliche Verteilung der von Stresssymptomen betroffenen Blätter (BEHMANN et al., 2014d)

Daher sind grundsätzlich zwei verschiedene Ansätze der Stressdetektion mit räumlichem Kontext zu unterscheiden. Bei Stressoren mit Symptomen mit spezifischen räumlichen Formen können die Formcharakteristika für eine Identifikation des Stressors genutzt werden (z.B. CAMARGO & SMITH, 2009). Methodisch werden hierfür Verfahren aus der Binärbildverarbeitung

und Mustererkennung verwendet. Bei Stressoren, welche die Pflanze als Ganzes betreffen, ist dieser Ansatz nicht zielführend, vielmehr gilt es hier die stressinduzierten Veränderungen innerhalb der Pflanze von der natürlichen Variabilität zu differenzieren.

Für den Skalenübergang vom Pixel auf die Pflanze gibt es verschiedene Ansätze die unterschiedlichen Generalisierungsannahmen machen. Einerseits ist es möglich, den mittleren Befallsgrad aller Pixel, die der Pflanze zugeordnet wurden, als charakterisierend für die gesamte Pflanze anzusehen. Beachtet werden muss dabei, dass die Variabilität innerhalb der Pflanze nicht repräsentiert werden kann. In BEHMANN et al. (2014d) wurde ein Ansatz beschrieben, der das Histogramm der Klassenverteilung als Beschreibung des Zustands der Pflanze nutzt. Die Variabilität wird durch die relativen Häufigkeiten repräsentiert und beliebige diskrete Verteilungen können realisiert werden.

Die Position von Stresssymptomen innerhalb der Pflanze ist entscheidend für die Auswirkungen, da z.B. betroffene Blätter im Randbereich Anzeichen des normalen Lebenszyklus der Pflanze oder einem geringen Stressdrucks sein können. Sollten jedoch Stresssymptome in den zentralen Bereichen der Pflanze, in der üblicherweise neue junge Blätter gebildet werden, auftreten, spricht dies eher für einen starken Stressdruck oder spezifische, lokal auftretende Stresssymptome. Diese räumliche Variabilität wurde bisher nicht betrachtet, bei einer zukünftigen, weiteren Erhöhung der räumlichen Auflösung könnte derartigen Verfahren jedoch eine wichtige Rolle zukommen.

Die Detektion von Stresssymptomen basierend auf spektralen Beobachtungen und in noch höherem Maße die Interpretation in ihrem räumlichen Kontext ist ein Anwendungsfeld mit noch hohem Entwicklungspotential (BEHMANN et al. 2014a).

5 Fazit

Hyperspektrale Kameras besitzen ein großes Potential für die Detektion und Identifikation von Pflanzenstress im Nahbereich, welches bei weitem noch nicht ausgeschöpft ist. Die mit derartigen Sensoren aufgezeichneten Daten sind sehr komplex und erfordern fortgeschrittene Verfahren der Datenanalyse. Im Bereich der Fernerkundung liegt bereits ein hohes Maß an Erfahrung vor, welche aktuell auf die neue Skala übertragen und angepasst wird. Eine besondere Rolle nehmen dabei die Methoden des maschinellen Lernens ein. Sie machen weniger Annahmen über die statistische Verteilung der Daten, welche bei hyperspektralen Bildern häufig unbekannt ist.

Besonderheiten der Nahbereichsskala sind dabei insbesondere die hohe räumliche Varianz im Vergleich zu typischen Anwendungsbereichen der Fernerkundung. Typischerweise werden einzelne Pflanzen oder Blätter untersucht, die durch ihre Geometrie oder kleinskalige Stresssymptome intern eine hohe Varianz aufweisen. Daher besitzen Methoden, die die präzise Detektion von Stresssymptomen auf Pixelebene mit einer geeigneten Auswertung der räumlichen Verteilung kombinieren eine herausgehobene Rolle für die Qualität der Information auf Ebene der Pflanze. Dies ist dann auch die relevante Ebene für die Phänotypisierung, da nur hier Verbindungen zwischen dem Genotyp und dem Phänotyp einer Pflanze hergestellt werden können.

Anfälligkeiten bzw. Resistenzen gegenüber bestimmten Stressoren stellen als spezifische phänotypische Eigenschaft ein wichtiges Merkmal für die Ertragsfähigkeit einer Pflanze dar. Diese Merkmale sind von besonderem Interesse für Züchtung und Ertragsmanagement und werden dazu beitragen den gesteigerten Nahrungsmittelbedarf für eine wachsende Weltbevölkerung zu decken.

6 Danksagung

Die Autoren bedanken sich für die Förderung des Projekts CROP.SENSE.net im Kontext des Ziel 2 Programms NRW 2007-2013 „Regionale Wettbewerbsfähigkeit und Beschäftigung (EFRE)“ durch das Ministerium für Innovation, Wissenschaft und Forschung (MIWF) des Landes Nordrhein-Westfalens (NRW) und dem Fond für Regionale Entwicklung (EFRE) (005-1103-0018) der Europäischen Union während der Erstellung dieses Manuskripts.

7 Literaturverzeichnis

- BARETH, G., AASEN, H., BENDIG, J., GNYP, M.L., BOLTEN, A., JUNG, A., MICHELS, R. & SOUKKAMÄKI, J., 2015: Low-weight and UAV-based hyperspectral full-frame cameras for monitoring crops: spectral comparison with portable spectroradiometer measurements. *Photogrammetrie, Fernerkundung, Geoinformation (PFG)*, 1.
- BEHMANN, J., MAHLEIN, A.-K., PAULUS, S., KUHLMANN, H., OERKE, E.-C. & PLÜMER, L., 2014a: Generation and application of hyperspectral 3D plant models. *ECCV 2014 Workshop on Computer Vision Problems in Plant Phenotyping (CVPPP 2014)*.
- BEHMANN, J., MAHLEIN, A.-K., RUMPF, T., RÖMER, C. & PLÜMER, L., 2014b: A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, doi: 10.1007/s11119-014-9372-7 (online first).
- BEHMANN, J., SCHMITTER, P., STEINRÜCKEN, J. & PLÜMER, L., 2014c: Ordinal classification for efficient plant stress prediction in hyperspectral data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **XL-7**, S. 29-36.
- BEHMANN, J., STEINRÜCKEN, J. & PLÜMER, L., 2014d: Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing* **93**, S. 98-111.
- BREIMAN, L., 2001: Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical Science* **16** (3), S. 199-231.
- CABRERA-BOSQUET, L., CROSSA, J., VON ZITZEWITZ, J., SERRET, M. D. & LUIS ARAUS, J. (2012). High-throughput Phenotyping and Genomic Selection: The Frontiers of Crop Breeding Converge. *Journal of integrative plant biology* **54** (5), 312-320.
- CAMARGO, A. & SMITH, J. S., 2009: Image pattern classification for the identification of disease causing agents in plants. *Computers and Electronics in Agriculture* **66** (2), S. 121–125.

- ERDLE, K., MISTELE, B. & SCHMIDHALTER, U., 2011: Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. *Field Crops Research* **124** (1), S. 74-84.
- FURBANK, R. T., & TESTER, M., 2011: Phenomics–technologies to relieve the phenotyping bottleneck. *Trends in plant science* **16** (12), S. 635-644.
- GASPAR, T., FRANCK, T., BISBIS, B., KEVERS, C., JOUVE, L., HAUSMAN, J. F. & DOMMES, J., 2002: Concepts in plant stress physiology. Application to plant tissue cultures. *Plant Growth Regulation* **37** (3), S. 263-285.
- GRIETENS, B., 2008: From micro to macro: NIR sensors and imaging spectroscopy – a perfect match. *Photonik international* **1**, S. 36-39.
- JENSEN, J. 2009. *Remote Sensing of Environment: An Earth resource Perspective*. (2nd ed.), Pearson Prentice Hall.
- MAHLEIN, A. K., RUMPF, T., WELKE, P., DEHNE, H. W., PLÜMER, L., STEINER, U. & OERKE, E. C., 2013: Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment* **128**, S. 21-30.
- RÖMER, C., WAHABZADA, M., BALLVORA A., PINTO. F., ROSSINI, M., PANIGADA, C., BEHMANN J., LÉON, J., THURAU, C., BAUCKHAGE, C., KERSTING, K., RASCHER, U. & PLÜMER, L., 2012: Early drought stress detection in cereals: simplex volume maximisation for hyperspectral image analysis. *Functional Plant Biology* **39**, S. 878-890
- RUMPF, T., MAHLEIN, A. K., STEINER, U., OERKE, E. C., DEHNE, H. W. & PLÜMER, L., 2010: Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture* **74** (1), S. 91-99.
- TAIZ, L. & ZEIGER, E., 2010: *Plant physiology*. (5th ed.), Sinauer Associates, Sunderland and Mass.