

Institut für Geodäsie und Geoinformation
Geoinformation

Integration von
hyperspektralen Merkmalen und 3D-Geometrie für
die Klassifikation von Pflanzenstressprozessen

Inaugural-Dissertation

zur

Erlangung des Grades

Doktor der Ingenieurwissenschaften

(Dr.-Ing.)

der

Landwirtschaftlichen Fakultät

der

Rheinischen Friedrich-Wilhelms-Universität Bonn

von

M.Sc. Jan Behmann

aus

Haan

Bonn 2016

Referent: Prof. Dr. Lutz Plümer
Korreferent: Prof. Dr.-Ing. Heiner Kuhlmann
Externer Gutachter: Dr. Hanno Scharr

Tag der mündlichen Prüfung: 26.09.2016

Kurzfassung

Hyperspektrale Kameras eröffnen neue Zugänge zur nicht-invasiven Beobachtung physiologischer Prozesse in der Pflanze, die zu einem tieferen Verständnis von Stresstoleranz und Ertragsbildung beitragen können, wenn es gelingt die Sensoren richtig zu modellieren und die Signale angemessen zu interpretieren. Diese Arbeit adressiert drei Teilprobleme: die Modellierung der Stressausbreitung durch ein ordinale Klassifikationsmodell, die geometrische Kalibrierung der hyperspektralen Kameras und die Verknüpfung geometrischer und spektraler Informationen für die Verbesserung des Signal-zu-Rausch-Verhältnisses.

Ausgangspunkt waren die folgenden Randbedingungen für die Stressdetektion in hyperspektralen Bildern: Da die Auswirkungen von Stress im frühen Stadium für das bloße Auge unsichtbar sind, fehlen als Voraussetzung für überwachte Lernverfahren Labelinformationen auf Pixelebene. Darüber hinaus beeinflusst die Pflanzengeometrie als Störgröße das beobachtete Reflektanzspektrum, sodass der relevante pflanzen-physiologische Parameter im Signal überlagert werden kann.

Das ordinale Klassifikationsmodell basiert auf unüberwacht gewonnenen Labelinformationen und erfasst auch frühe, noch unsichtbare Anzeichen. Dieses Analysemodell wurde im Hinblick auf Echtzeitfähigkeit durch Einbeziehung der spezifischen Eigenschaften der Trockenstressreaktion entwickelt. Es ermöglicht den Einsatz linearer Support Vektor Maschinen in optimierten Merkmalsräumen und erfasst auch Zwischenstadien der Trockenstressreaktion. Repräsentative Trainingsdaten mit geringem Messrauschen werden unter Nutzung des kontinuierlichen Ausbreitungsmusters der Reaktion gewonnen, indem diese nur aus ausgewählten Bildregionen mit homogenem Reflektanzverhalten extrahiert werden. Bei der frühen Erkennung von Trockenstress auf Gerste zeigte sich dieses vollautomatische Verfahren gegenüber allen etablierten Vegetationsindizes als deutlich überlegen und detektierte den Trockenstress signifikant früher als z.B. der bekannte NDVI.

Es wird ein geometrisches Kalibrierverfahren für hyperspektrale Pushbroom-Kameras vorgestellt und dieses zur Kombination der 3D-Pflanzenmodelle mit den Hyperspektralbildern genutzt. Das Kalibrierverfahren für den Nahbereich nutzt ein zu diesem Zweck entworfenes Referenzobjekt und erweitert das lineare Kameramodell um einen nicht-linearen Term auf Basis von Polynomen. Dieser Ansatz ermöglicht die Verknüpfung der Hyperspektralbilder mit den 3D-Modellen auf Ebene einzelner Pixel und somit die Erstellung hyperspektraler 3D-Pflanzenmodelle mit Subpixelgenauigkeit.

Es wurden drei Modelle zur Integration der 3D-Merkmale Neigung und Distanz in die Analyse des hyperspektralen Signals entwickelt und verglichen. Der Effekt der distanzabhängigen Beleuchtungsstärke wird durch ein funktionales Modell im Signal korrigiert. Die Neigung wird in einem maschinellen Lernverfahren zur Reduktion der Geometrieeffekte im Prädiktionsergebnis hinzugezogen. Der geometrische Zusammenhang zwischen Anzahl der Pixel und Blattoberfläche wird zur Interpretation von Prädiktionsergebnissen modelliert.

Das in dieser Arbeit vorgestellte ordinale Klassifikationsverfahren ermöglicht eine frühzeitige und ressourceneffiziente Detektion von Trockenstress. Durch die Kamerakalibrierung wurden erstmals die Effekte der Pflanzengeometrie im Nahbereich und auf Ebene einzelner Pixel untersucht und bei der Interpretation von Hyperspektralbildern berücksichtigt. Diese Modelle und Methoden unterstützen die Datenanalyse hyperspektraler Kameras, eine Technologie, die Prozesse beobachten kann, ohne ihre Entwicklung zu beeinflussen.

Abstract

Hyperspectral cameras create new points of access for the non-invasive observation of physiological processes in plants. They can contribute to a deeper understanding of stress tolerance and yield building, if the sensors are correctly modeled and the signals are interpreted in a suitable way. This work addresses three parts of the task: modeling the stress dispersion by an ordinal classification model, the geometric calibration of hyperspectral cameras and the integration of geometric and spectral information for the improvement of signal-to-noise-ratio.

This work is motivated by two restrictions: as the effects of stress in an early stage are invisible for the human eye, label information is missing, which is a prerequisite for supervised learning methods. Moreover, the plants' geometry influences the observed reflectance spectra as a noise factor in a way that can cover the relevant plant-physiological parameter in the signal.

The ordinal classification model is based on unsupervised generated label information and, therefore, recognizes also the early, still invisible stress signs. This analysis model was designed with regard to realtime capabilities by including the specific characteristics of the drought stress reaction. It allows the application of linear Support Vector Machines in optimized feature spaces and captures also transfer states of the drought stress reaction. Representative training data with low noise level are derived by using the continuous distribution pattern of the reaction. They are only extracted from selected image regions with homogeneous reflectance characteristics. For the early detection of drought stress on barley, this fully automatic method outperforms all established Vegetation Indices and detects drought stress significantly earlier as for example the well known NDVI.

A geometric calibration method for hyperspectral pushbroom cameras is presented and it is used for the combination of 3D plant models with hyperspectral images. The close-range calibration method is based on a reference object designed for this purpose and extends the linear camera model by a non-linear term based on polynomials. This approach allows the referencing of hyperspectral images and 3D plant models at the scale of single pixels and the generation of hyperspectral 3D plant models with sub-pixel accuracy.

Three models for the integration of the 3D features inclination and distance into the analysis of the hyperspectral signal were developed and compared. The effect of distance dependent illumination is corrected by a functional model in the signal. The inclination is used in a machine learning method for reducing the geometry effects in the predictions. The geometric relation between number of pixels and leaf surface area is modeled for improved interpretation of prediction results.

The introduced ordinal classification method enables an early and resource efficient detection of drought stress. Using the camera calibration, the effects of the plants' geometry are investigated in the close range as well as on the scale of single pixels for the first time and regarded for the interpretation of hyperspectral images. These models and methods support the data analysis for hyperspectral cameras, a method that observes processes without interfering with them.

Inhaltsverzeichnis

1	Einleitung	1
2	Sensoren und Methoden	9
2.1	Nicht-invasive Sensoren zur Erfassung pflanzen-physiologischer Eigenschaften	9
2.1.1	Hyperspektrale Sensoren	9
2.1.2	Geometriesensoren	12
2.1.3	Modellierung der Abbildungseigenschaften hyperspektraler Kameras	14
2.2	Ausgewählte Methoden zur Interpretation hyperspektraler Daten	17
2.2.1	Unüberwachtes Labeln eines ordinalen Prozesses	18
2.2.2	Ordinale Klassifikation	19
2.2.3	Merkmalsselektion	21
2.2.4	Support Vektor Maschinen und Span-Estimate	22
2.2.5	Support Vector Data Description	25
3	Zusammenfassung der wichtigsten Ergebnisse	29
3.1	Ordinale Klassifikation für die Detektion von Trockenstress	29
3.2	Sensorfusion für hyperspektrale 3D-Pflanzenmodelle	35
3.3	Geometrische 3D-Merkmale zur Reduktion von Störgrößen	40
4	Schlussfolgerungen und Ausblick	47
	Literaturverzeichnis	51
A	Auflistung der eigenen Publikationen	57
A.1	Auflistung der beigefügten Publikationen	57
A.2	Auflistung der übrigen Publikationen	57
B	Beigefügte Publikationen	59
B.1	A review of advanced machine learning methods for the detection of biotic stress in precision crop protection	59
B.2	Detection of early plant stress responses in hyperspectral images	60
B.3	Low-cost 3D systems: suitable tools for plant phenotyping	61
B.4	Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping	62
B.5	Generation and application of hyperspectral 3D plant models: methods and challenges	63
B.6	Detection of disease symptoms on hyperspectral 3D plant models	64

1 Einleitung

Gegenstand dieser Arbeit ist die Entwicklung von Modellen und Analyseverfahren für Hyperspektralbilder, die die Ausbreitung von Stress in Pflanzen beschreiben und das Signal-zu-Rausch-Verhältnis verbessern.

Die hier vorgestellte Forschungsarbeit erfolgte im Rahmen des interdisziplinären Forschungsnetzwerks CROP.SENSE.net. Ziel dieses Netzwerks war die Anpassung der landwirtschaftlichen Produktion an die sich verändernde Nachfrage unter Beachtung von Auswirkungen des fortschreitenden Klimawandels wie beispielsweise Trockenheit (CROP.SENSE.net, 2014). Es wurden Technologien erforscht, die es erlauben auch unter derart schwierigen Produktionsbedingungen Ertragsverluste zu vermeiden und gleichzeitig den Ressourceneinsatz effizienter zu gestalten. Dazu wurden Sensoren und Analyseverfahren entwickelt, um die Zustände und Eigenschaften auf Ebene der Einzelpflanze und im Bestand zu erfassen. Ein Schwerpunkt war die Datenanalyse bei hyperspektralen Kameras, da diese wertvolle Einblicke in physiologische Prozesse der Pflanze mit hoher räumlicher und spektraler Auflösung ermöglichen. Zur Auswertung der anfallenden großen Datenmengen bildgebender Sensoren werden effiziente Analyseverfahren benötigt (Minervini et al., 2015). Die automatisierte Beobachtung und Auswertung großer Datenmengen zur Analyse von Pflanzeigenschaften stellt als Phänotypisierung einen aktuellen Trend dar und ist zur Bewältigung der Herausforderungen, der sich die Pflanzenzucht in Zeiten des Klimawandels stellt, unverzichtbar. Die Ergebnisse der Phänotypisierung können in Kombination mit Informationen über die Genotypen neue Impulse für die beschleunigte Züchtung robuster Pflanzensorten geben (Furbank und Tester, 2011). Phänotypisierungssysteme, die vielfältige phänotypische Merkmale einer signifikanten Anzahl von Pflanzen hochaufgelöst erfassen, besitzen folglich das Potenzial die aktuellen Herausforderungen der landwirtschaftlichen Produktion zu adressieren. In diesem Kontext spielen hyperspektrale Sensoren eine bedeutende Rolle.

Das Teilprojekt von CROP.SENSE.net, in dessen Rahmen die vorliegende Arbeit erstellt wurde, befasste sich mit der Detektion von abiotischen Stresssymptomen aus hyperspektralen Reflektanzinformationen der Blattoberflächen von Nutzpflanzen. Ziel war eine frühestmögliche Klassifikation von Stresszuständen. Entscheidend für die Anwendung der Klassifikation als überwachtetes Lernverfahren sind geeignete Label, die hier jedoch aufgrund der mit bloßem Auge nicht beobachtbaren frühen Stadien nicht verfügbar sind. Infolgedessen existiert keine Referenz der Stressreaktion, die zur Herleitung eines Modells oder Bewertung der Prädiktionsqualität hinzugezogen werden kann. Das hyperspektrale Signal wird darüber hinaus entscheidend durch Effekte der Pflanzengeometrie beeinflusst und physiologische Parameter im Signal potentiell überdeckt. Dieses schlechte Signal-zu-Rausch-Verhältnis kann auf die differenzierte Blattarchitektur der hier untersuchten Nutzpflanzen Gerste und Zuckerrübe zurückgeführt werden.

Zur Veredelung und Analyse dieser Daten wurden überwachte und unüberwachte Verfahren des maschinellen Lernens kombiniert und die hyperspektralen Bilder um 3D-Pflanzenmodelle bzw. die Spektren um geometrische 3D-Merkmale ergänzt.

Analyse und Klassifikation hyperspektraler Signale

Die Analyse der Messdaten hyperspektraler Kameras steht im Fokus dieser Arbeit. Dieser Sensortyp beobachtet die Reflektanzcharakteristik einer Vielzahl von Oberflächenpunkten in über hundert Frequenzbändern. Durch berührungslose Messung, üblicherweise im sichtbaren Teil des Lichtspektrums und im nahen Infrarotbereich, werden Rückschlüsse auf eine Reihe von pflanzen-physiologischen Eigenschaften möglich. Ihre zeitliche Entwicklung ist durch Zeitreihenaufnahmen dieser nicht-destruktiven Messtechnik beobachtbar. Pflanzenstress verändert das hyperspektrale Reflektanzspektrum, da in diesem Fall unter anderem Pigmente in einem kontrollierten Prozess abgebaut werden. Abb. 1.1 zeigt neben der RGB Visualisierung eine kartenhafte Darstellung der zeitlichen Entwicklung des lokalen Stresszustands einer Gerstenpflanze. Diese Beschreibung des Stresszustands wurde mit einem Klassifikator, genauer einer ordinalen Support Vektor Maschine (SVM), gewonnen. Sichtbar wird der fortschreitende Stressprozess durch sein räumliches Ausbreitungsmuster, welches durch das Farbbild (RGB) nicht erfasst wird. Diese Abbildung zeigt das Ergebnis einer komplexen Datenanalyse, die auf den umfangreichen Vorarbeiten im Bereich der Analyse hyperspektraler Bilder aufbaut, in einigen kritischen Punkten jedoch auch über diese hinausgeht.

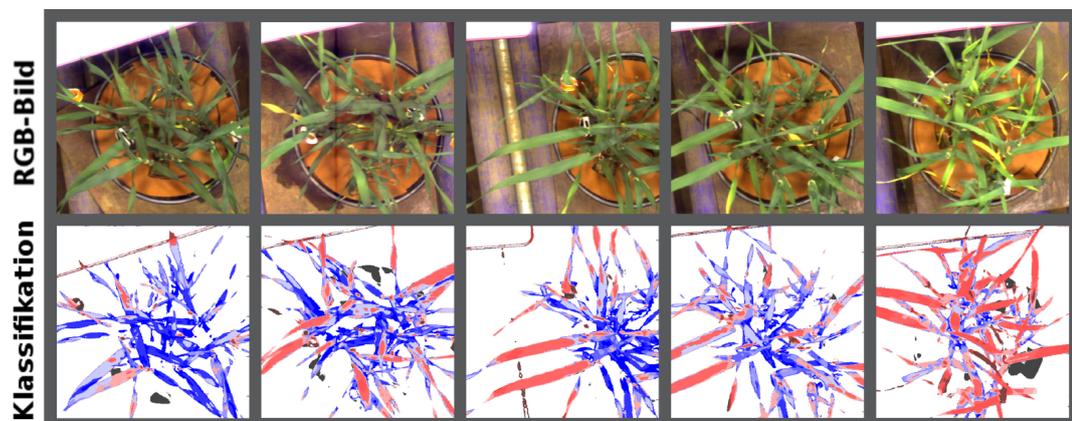


Abbildung 1.1: Ausbreitung von Trockenstress in einer Gerstenpflanze für jeden zweiten Tag eines Zeitreihenexperiment. Dargestellt ist sowohl der optische Eindruck (oben), als auch das Ergebnis der Interpretation des Hyperspektralsbilds durch eine ordinale SVM (blau=vital und rot=seneszent, modifiziert aus Behmann et al., 2014c).

Hyperspektrale Sensoren werden bereits seit Jahrzehnten für die Erfassung von Pflanzeigenschaften sowohl in der weltraum- und luftgestützten Fernerkundung, als auch im Nahbereich eingesetzt (z.B. Zarco-Tejada et al., 2001; Tarnavsky et al., 2008; Stagakis et al., 2012). Zur Auswertung hyperspektraler Sensordaten werden in der Fernerkundung Vegetationsindizes (VI) angewendet. Man schließt damit aus der Reflektanzinformation auf einen

physiologischen Parameter, wie z.B. eine Pigmentkonzentration (Thenkabail et al., 2000; Blackburn, 2007). Diese VI sind Funktionen einzelner spektraler Bänder (häufig 2-3), die einen ausgewählten Prozess oder Parameter hervorheben und dabei möglichst robust gegenüber dem Einfluss von Störgrößen sind. Der bekannteste Vegetationsindex ist der NDVI (normalized difference vegetation index), der die Vitalität, bzw. den Chlorophyllgehalt abschätzt und dabei eine gewisse Robustheit gegenüber Helligkeitsschwankungen aufweist (Rouse et al., 1974). Er berechnet sich aus einer selbstnormierenden Differenz der Reflektanz im nahen Infrarot (NIR) und im roten Spektralbereich (Rot):

$$NDVI = \frac{NIR - Rot}{NIR + Rot} \quad (1.1)$$

Allerdings sind einzelne Vegetationsindizes zur Detektion von Stress nur bedingt geeignet, da sie häufig für spezifische Fernerkundungssensoren mit deutlich weniger beobachteten Frequenzbändern (z.B. Landsat-1 mit sieben Kanälen) entwickelt wurden. Folglich wird ein Großteil der spektralen Information aktueller Sensoren durch die Verwendung vereinzelter Bänder nicht genutzt.

Um diese Nachteile zu kompensieren ohne die Vorteile der VI einzubüßen, wurden in unserer Arbeitsgruppe von Rumpf et al. (2010) im Journal *Computers and Electronics in Agriculture* verschiedene Vegetationsindizes in einem Merkmalsset kombiniert. Mittels einer nicht-linearen SVM wurden Symptome von drei unterschiedlichen Krankheiten auf Zuckerrübenblättern differenziert, bevor diese für das bloße Auge sichtbar wurden. Ein ähnlicher Ansatz wurde darauf aufbauend von Römer et al. (2011) für Weizenbraunrost verfolgt, wobei anstatt der VI die Koeffizienten von Polynomen, die Teile des Fluoreszenzspektrums approximieren, als Merkmale genutzt wurden. Hierbei ist zu beachten, dass diese Merkmale anhand hyperspektraler Fluoreszenzspektren entwickelt wurden, die eine mit dem Reflektanzspektrum nicht vergleichbare Rauschcharakteristik aufweisen. In den Arbeiten wird zwischen gesund und krank bzw. drei Krankheiten differenziert. Folglich handelt es sich um nominale Klassifikationsmodelle, die diskrete Klassen ohne natürliche Ordnung präzisieren.

Für die Abschätzung der Übertragbarkeit dieser Klassifikationsmodelle auf Trockenstress muss man den Ablauf der Trockenstressreaktion genauer betrachten. Trockenstress, im Gegensatz zu den Pflanzenkrankheiten, induziert eine Trockenstressreaktion, die die gesamte Pflanze umfasst und durch eine fortschreitende Verschiebung der hyperspektralen Reflektanzeigenschaften geprägt ist. Dieser Prozess läuft in den Blättern der Pflanze nicht synchronisiert, sondern als durch die Pflanze gesteuerter Prozess zeitlich versetzt ab. Beginnend bei den Blattspitzen der ältesten Blätter werden Pigmente abgebaut und Ressourcen wie Wasser in andere, zentralere und häufig jüngere Pflanzenteile verlagert. Da dieser Vorgang auf den Blättern kontinuierlich abläuft, weisen benachbarte Bereiche eine ähnliche Vitalität auf. Dieser beschleunigte Wandel von der vitalen zur abgestorbenen Pflanze wird auch als vorzeitige Seneszenz bezeichnet (Taiz und Zeiger, 2010). Die Trockenstressreaktion weist zwei entscheidende Unterschiede zu Symptomen der genannten Pflanzenkrankheiten auf. Erstens sind die frühen Stadien der Trockenstressreaktion für das bloße Auge unsichtbar, jedoch führen sie bereits zu leichten Abweichungen im beobachteten Spektrum. Zweitens ist für die Beschreibung des Zustandes einer Pflanze der schleichende Übergang von vital zu seneszent entscheidend. Die bisherigen Ansätze differenzieren jedoch zwischen nominalen

Zuständen, die der Entwicklung der Trockenstressreaktion nicht gerecht werden. Die Folge einer Anwendung nominaler Modelle zur Trockenstressdetektion wäre ein vermeidbarer Informationsverlust durch die Dateninterpretation, der eine tiefer gehende Untersuchung des raum-zeitlichen Prozesses erschwert.

Komplexere Prädiktionsmodelle, die diesen Informationsverlust reduzieren, gehen jedoch in der Regel einher mit höheren Anforderungen an die Label der Trainingsdaten, was insbesondere bei den frühen Stadien der Stressreaktion problematisch ist. Label repräsentieren die annotierten Bedeutungen der einzelnen Trainingsdaten, z.B. Klassenzugehörigkeit oder Befallsgrade. Regressionsmodelle entsprechen in ihrer Struktur kontinuierlichen Prozessen, erfordern im Gegenzug aber auch kontinuierliche Label, die für hyperspektrale Daten häufig nicht verfügbar sind. Ordinale Label sind die Voraussetzung für ordinale Klassifikationsverfahren und ergänzen die nominalen Label durch eine zusätzliche natürliche Rangfolge, sodass man auch von einer ordinalen Skala spricht. Sie werden sowohl bezüglich Informationsgehalt, als auch Komplexität ihrer Gewinnung zwischen nominalen und kontinuierlichen Labeln eingeordnet (Agresti, 2002).

Falls keine geeigneten Labelinformationen verfügbar sind, können unüberwachte Lernverfahren einen Ausweg darstellen. Sie stützen sich nicht auf Label, sondern identifizieren Strukturen bzw. Muster in den Daten und wurden beispielsweise von Römer et al. (2012) zur Detektion von Stress basierend auf Hyperspektralbildern eingesetzt. Das dort genutzte Verfahren repräsentiert alle Pixel des Datensatzes als Linearkombination ausgewählter Extrempunkte, sogenannter Archetypen. Zur Analyse dieser Linearkombinationen wurde jedoch auf nominale Label zurückgegriffen. Dazu wurden die Archetypen in vital und gestresst eingeteilt und der Zustand der Pflanze aus dem Anteil der jeweiligen Archetypen gewonnen.

Einfluss der Geometrie auf das hyperspektrale Signal

Neben der Problematik, dass die interessanten frühen Stadien der Trockenstressreaktion nicht sichtbar sind und in Folge dessen auch keine Label vorliegen, erschwert ein weiteres Phänomen alle Verfahren zur Gewinnung physiologischer Parameter aus hyperspektralen Bildern. Die hyperspektralen Sensoren besitzen ein sehr schlechtes Signal-zu-Rausch-Verhältnis, da eine große Anzahl von Faktoren sich auf das hyperspektrale Signal auswirken. Großen Anteil daran haben Effekte der Geometrie der Pflanze. Das hyperspektrale Spektrum ist folglich ein Mischsignal, dessen vielfältige Prozesse und Effekte ein Isolieren der relevanten Signalkomponente erschweren. Insbesondere die Distanz der Pflanzenoberfläche zur Lichtquelle und die lokale Blattneigung haben großen Einfluss, sodass in eigenen Experimenten mit Zuckerrüben bis zu 60% der spektralen Varianz durch diese geometrischen 3D-Merkmale begründet war. Auch robuste Vegetationsindizes sind massiv von der lokalen Blattneigung betroffen (Kassalainen et al., 2016).

Die Erfassung, geometrische Referenzierung und Integration der 3D-Pflanzengeometrie in den Analyseprozess ist daher entscheidend um das Potenzial hyperspektraler Kameras weiter auszuschöpfen. Pixelgenau referenzierte Farb-, Thermal- und Tiefenbilder werden von Raza et al. (2015) genutzt, um eine Pflanzenkrankheit bei Tomaten zu detektieren. Der dort gewählte Ansatz ist jedoch nicht übertragbar, da die Geometrie der Pflanze nur unvollständig erfasst wird und das Modell der perspektivischen Thermographie-Kamera die von uns verwendeten Pushbroom-Hyperspektralkameras nicht beschreiben kann.

Beitrag dieser Arbeit zur Analyse hyperspektraler Bilder

Ausgangspunkt dieser Arbeit sind die Defizite, die sich im Bezug auf die Klassifikationsverfahren für die frühzeitige Detektion von Trockenstress und das schlechte Signal-zu-Rausch-Verhältnis aufgrund der Effekte der Blattgeometrie gezeigt haben. Folgende Punkte werden daher adressiert um die frühzeitige, automatisierte Detektion von Pflanzenstress in Hyperspektralbildern weiterzuentwickeln.

1. Fehlende Labelinformationen für die noch unsichtbaren Stadien von Trockenstress verhindern die direkte Anwendung von überwachten Lernverfahren. Somit ist unklar, wie Klassifikationsmodelle gelernt werden können, die auch die frühen Stadien detektieren. Eine nominale Differenzierung in die zwei Klassen „vital“ und „gestresst“ blendet die Informationen der Zwischenstadien aus, sodass Verfahren für die Detektion von Krankheitssymptomen nicht direkt auf Trockenstress übertragbar sind.

In Kapitel 3.1 wird eine Methode zur unüberwachten Annotation in Kombination mit einem ordinalen Klassifikationsmodell für die Erfassung von Trockenstress eingeführt, die die wertvollen Informationen der Übergangsstadien durch den angepassten Interpretationsansatz erhält.

2. Hyperspektrale Kameras werden seit Jahrzehnten eingesetzt. Bei Phänotypisierungsszenarien stand ihre Abbildungsgeometrie jedoch nicht im Fokus. Für die geometrische Referenzierung mit 3D-Pflanzenmodellen ist diese nun erforderlich, jedoch sind Standardverfahren der Kamerakalibrierung nicht anwendbar.

In Kapitel 3.2 wird zur genauen und effizienten Bestimmung der Kameraparameter das lineare Pushbroom-Kameramodell um die nicht-linearen Phänomene des Nahbereichs erweitert und ein Referenzobjekt entworfen, welches die Hyperspektralkamera und 3D-Laserscanner in einem konsistenten Koordinatensystem vereint.

3. Die Pflanzengeometrie beeinflusst massiv das beobachtete hyperspektrale Signal. Neben dem physiologischen Zustand der Pflanze bestimmen eine Vielzahl von Faktoren die gemessene Reflektanz, wobei die Geometrie der Pflanze den dominanten Anteil stellt. Die referenzierten 3D-Modelle ermöglichen die Erweiterung des Merkmalsraum mit geometrischen 3D-Merkmalen, jedoch ist unklar mit welchen Modellen die 3D-Geometrie in die Analyse integriert werden kann.

In Kapitel 3.3 werden die geometrischen 3D-Merkmale der Blattneigung und der Distanz zur Beleuchtung in den Analyseprozess durch funktionale Modelle und Methoden des maschinellen Lernens integriert.

Die Kombination der ordinalen Klassifikation mit einem unüberwachten Verfahren zur Annotation adressiert die verbesserte Repräsentation des Trockenstressprozesses und wurde von Behmann et al. (2014c) im *ISPRS Journal of Photogrammetry and Remote Sensing* veröffentlicht. Die benötigten ordinalen Label werden in einem unüberwachten, zweistufigen Verfahren gewonnen, das auch die frühen, noch unsichtbaren Stadien differenziert. Hier werden zuerst nominale Label durch eine Clusteranalyse bestimmt und diese in der zweiten Stufe durch etablierte Stressindikatoren linear geordnet und somit zu ordinalen Labeln transformiert. Das darauf aufbauende ordinale Klassifikationsmodell bildet erstmals die kontinuierliche Entwicklung und Ausbreitung des Stresses in einer Pflanze auf eine ordinale Skala ab. Dieses Modell umfasst ausschließlich die Trennfunktionen zwischen Klassen, die

auf der ordinalen Skala direkt benachbart sind. Diese Trennfunktionen werden unabhängig voneinander bestimmt, sodass es außerdem erstmals möglich wird optimale Merkmalskombinationen spezifisch für die einzelnen Stufen des Stressprozesses zu selektieren.

Für die Referenzierung von Geometrie und hyperspektralen Reflektanzeigenschaften, wird die Form der Pflanze mit einem industriellen Laserscanner separat erfasst und die Abbildungseigenschaften der Kamera im Koordinatensystem des 3D-Pflanzenmodells beschrieben. Das Verfahren der Kamerakalibrierung zur Erzeugung hyperspektraler 3D-Pflanzenmodelle wurde von Behmann et al. (2015b) im *ISPRS Journal of Photogrammetry and Remote Sensing* veröffentlicht. Da die Geometrie hochvariabel ist, müssen auch die Geometriemerkmale lokal den einzelnen Pixeln zugeordnet werden. Hier wurde ein Verfahren eingeführt, welches, im Gegensatz zum Modell der linearen Pushbroom-Kamera, die kombinierten nicht-linearen Phänomene des Nahbereichs umfasst und die Abbildungseigenschaften mit dem 3D-Modell durch ein dafür entworfenes Referenzobjekt verknüpft. Dies ermöglicht eine praktikable Zuordnung von Spektren und geometrischen 3D-Merkmalen, wie Neigung und Distanz auf Ebene einzelner Pixel. Basierend auf den hyperspektralen 3D-Pflanzenmodellen entsteht ein erweiterter Merkmalsraum, der die Grundlage zur Modellierung der Abhängigkeiten zwischen Geometrie und spektralen Merkmalen darstellt.

Wie diese zusätzliche Geometrieinformation für eine genauere Analyse und eine Verbesserung des Signal-zu-Rausch-Verhältnisses nutzbar gemacht werden können, ist dabei von den Charakteristiken des untersuchten geometrischen Effekts abhängig (Behmann et al., 2015a; Roscher et al., 2016a). Beim bekannten Zusammenhang der quadratischen Abnahme der Beleuchtungsstärke mit zunehmender Distanz, wird ein explizites Korrekturmodell basierend auf Messungen des Phänomens angewendet. Der Effekt der Neigung hingegen ist stärker von den variablen Eigenschaften der Pflanze abhängig und mit dem vorhandenen Messaufbau nicht direkt messbar. Infolgedessen wird nicht der Effekt auf das spektrale Signal modelliert, sondern im Rahmen eines Ein-Klassen-Klassifikators die Neigung als zusätzliches Merkmal für die Detektion von Krankheitssymptomen genutzt. Damit wurde die Möglichkeit geschaffen die Signalqualität der hyperspektralen Kameras signifikant zu erhöhen und potentiell pflanzen-physiologische Prozesse zu untersuchen, die unter den bisherigen Bedingungen von Effekten der Geometrie verdeckt waren. Diese Verfahren öffnen die Tür zu einer ganzen Reihe neuartiger Kalibrierungsansätze, die weitere geometrische Effekte, wie Selbstverschattung und Mehrfachreflexionen adressieren.

In dieser Arbeit werden die Ergebnisse ausgewählter Publikationen über die Interpretation hyperspektraler Bilder zusammengefasst. Zu diesem Zweck wird sowohl die verwendete Methodik eingeführt, als auch Ergebnisse der Anwendung der Methoden auf erfasste Datensätze dargelegt und diskutiert. Die wesentlichen Beiträge dieser Arbeit zur verbesserten Interpretation hyperspektraler Bilder sind dabei folgende:

1. Einführung eines neuen Klassifikationsmodells zur angemessenen Repräsentation des Stressprozesses einhergehend mit spezifischen Merkmalskompositionen.
2. Einführung eines neuen, an den Nahbereich angepassten Pushbroom-Kameramodells für die Fusion der hyperspektralen Beobachtungen mit 3D-Pflanzenmodellen.
3. Verbesserung des Signal-zu-Rausch-Verhältnisses durch die Berücksichtigung der geometrischen Effekte in den gemessenen hyperspektralen Daten durch funktionale Modelle und Methoden des maschinellen Lernens.

Die vorliegende Arbeit gliedert sich daher wie folgt:

In Kapitel 2 werden die spezifischen Eigenschaften der Hyperspektralkamera und des 3D-Laserscanners, insbesondere im Bezug auf ihre geometrische Verknüpfung dargelegt. Darüber hinaus werden die mathematisch-statistischen Analyseverfahren eingeführt und ihre Eignung für die jeweilige Aufgabe diskutiert.

In Kapitel 3 werden die Verfahren und die wichtigsten Ergebnisse der zentralen Publikationen zusammengefasst. Für die Detektion von Trockenstress bei Gerstenpflanzen wird das Verfahren der ordinalen Klassifikation vorgestellt. Für die gegenseitige geometrische Referenzierung von Hyperspektralbild und 3D-Pflanzenmodell wird die Kalibrierung der hyperspektralen Kameras unter Einbeziehung eines nicht-linearen phänomenologischen Modellierungsansatzes eingeführt. Es werden Ansätze zur Verbesserung der Daten- und Ergebnisqualität basierend auf den gewonnenen geometrischen 3D-Merkmalen Distanz und Neigung anhand von Zuckerrübenpflanzen aufgezeigt.

In Kapitel 4 werden die gezogenen Schlussfolgerungen vorgestellt. Darauf aufbauend werden die zukünftigen Arbeiten dargelegt und Prognosen über die kommenden Entwicklungstrends in diesem dynamischen Forschungsfeld gegeben.

Für die vorliegende Arbeit sind folgende Publikationen wesentlich und daher beigefügt (thematisch geordnet):

Behmann, J., A.-K. Mahlein, T. Rumpf, c. Römer, und L. Plümer, 2014: A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, 16, 239-260. (equal contribution)

Behmann, J., J. Steinrücken, und L. Plümer, 2014: Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 98–111.

Paulus, S., J. Behmann, A.-K. Mahlein, L. Plümer, und H. Kuhlmann, 2014: Low-cost 3D systems: suitable tools for plant phenotyping. *Sensors*, 14, 3001–3018. (equal contribution)

Behmann, J., A.-K. Mahlein, S. Paulus, H. Kuhlmann, E.-C. Oerke, und L. Plümer, 2015: Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 172–182.

Behmann, J., A.-K. Mahlein, S. Paulus, J. Dupuis, H. Kuhlmann, E.-C. Oerke, und L. Plümer 2015: Generation and application of hyperspectral 3D plant models: methods and challenges. *Machine Vision and Applications*, 1–14. (online first)

Roscher R., J. Behmann, A.-K. Mahlein, J. Dupuis, H. Kuhlmann, und L. Plümer, 2016: Detection of disease symptoms on hyperspectral 3D plant models, *ISPRS Annals*, III–7, 89-96. (equal contribution)

Darüber hinaus wurde unter anderem ein Verfahren zur Klassifikation von Aktivitäten bei Kühen basierend auf Positions- und Herzfrequenzdaten publiziert. In dieser Publikation werden verwandte Analysemethoden verwendet, sie wird hier jedoch nicht diskutiert:

Behmann, J., K. Hendriksen, U. Müller, W. Büscher, und L. Plümer, 2016: Support Vector machine and duration-aware conditional random field for identification of spatio-temporal activity patterns by combined indoor positioning and heart rate sensors, *GeoInformatica*, 1–22. (online first)

2 Sensoren und Methoden

Im aktuellen Kapitel werden die verwendeten Sensoren und Analysemethoden vorgestellt, für das weitere Verständnis fundamentale Begriffe eingeführt und die Eignung für den jeweiligen Zweck diskutiert.

In Kapitel 2.1 werden die nicht-invasiven Sensoren Hyperspektralkamera und 3D-Laserscanner eingeführt. Die Qualität ihrer Messdaten ist einerseits Randbedingung für ihre Analyse, spezifiziert darüber hinaus aber auch die benötigte Referenzierungsgüte für die angestrebte Datenfusion. In Kapitel 2.1.3 wird die Kamerakalibrierung als Methode zur geometrischen Referenzierung von Bild- und Geometriedaten eingeführt.

In Kapitel 2.2 werden die verwendeten Analyseverfahren vorgestellt. Dabei werden die für das Verständnis der in Kapitel 3 gezeigten Ergebnisse benötigten Verfahren methodisch eingeführt. Der Schwerpunkt liegt auf der Klassifikation mit Support Vektor Maschinen (SVM). Anhand der zugrundeliegenden Mechanismen wird erläutert, warum sie für die Stressdetektion in hyperspektralen Datensätzen besonders geeignet sind.

2.1 Nicht-invasive Sensoren zur Erfassung pflanzen-physiologischer Eigenschaften

Nicht-invasive Sensoren haben bei der Beobachtung von physiologischen Eigenschaften von Pflanzen den großen Vorteil, dass sie die Pflanze weder verändern noch schädigen. Somit kann eine Pflanze mit verschiedenen Sensoren im Verlauf ihrer Vegetationsperiode mehrfach beobachtet werden. Dies reduziert einerseits den experimentellen Aufwand, da der Anbau und die versuchsspezifische Behandlung viele manuelle Arbeitsschritte erfordert. Andererseits sind nicht-invasive Sensoren eine zwingende Voraussetzung für Zeitreihenbeobachtung, welche wiederum der Erfassung von temporalen Prozessen dienen. Gemeinsamkeit der meisten nicht-invasiven Sensoren ist, dass sie die reflektierte elektromagnetische Strahlung messen, z.B. in Form der Reflektanzcharakteristik durch Hyperspektralkameras (Kapitel 2.1.1) oder der Pflanzengeometrie durch Laserscanner nach dem Triangulationsprinzip (Kapitel 2.1.2).

2.1.1 Hyperspektrale Sensoren

Stressprozesse verändern die Struktur und die Zusammensetzung innerhalb der Blätter und daher auch ihr Reflektionsverhalten. Hyperspektrale Sensoren messen den Anteil reflektierten Lichts in einer Vielzahl schmalbandiger Frequenzbereiche. Hyperspektrale Kameras beobachten dieses Reflektanzverhalten an einer Vielzahl von regelmäßig angeordneten

Oberflächenpunkten. Interpretiert als Pixel bilden sie ein hyperspektrales Bild mit zwei räumlichen Achsen (vgl. Abb. 2.1). In jedem Pixel dieses Bildes ist das beobachtete Reflektanzspektrum des dazugehörigen Oberflächenpunktes als dritte, spektrale Koordinatenachse gespeichert.

In den letzten Jahren gab es eine deutliche Weiterentwicklung der Technik verfügbarer Hyperspektralkameras. Dies betrifft sowohl die spektrale als auch die räumliche Auflösung. Die in CROP.SENSE.net eingesetzten Hyperspektralkameras messen das vom Untersuchungsobjekt reflektierte Spektrum im Bereich des sichtbaren Lichts und nahen Infrarots (400-1000nm, VISNIR) und des kurzwelligen Infrarots (1000-2500nm, SWIR) mit einer spektralen Auflösung von bis zu 1nm (Abb. 2.1). In diesen Spektralbereichen ermöglicht die Reflektanz Rückschlüsse auf verschiedene Blattpigmente, die Wasserabsorption und die Zellstruktur. Diese beeinflussen welche Anteile des einstrahlenden Lichts reflektiert, transmittiert und absorbiert werden. Die räumliche Auflösung dieser Kameras in üblicher Messdistanz von ca. 0,5m liegt im Bereich von einigen Millimetern bis in den Submillimeterbereich.

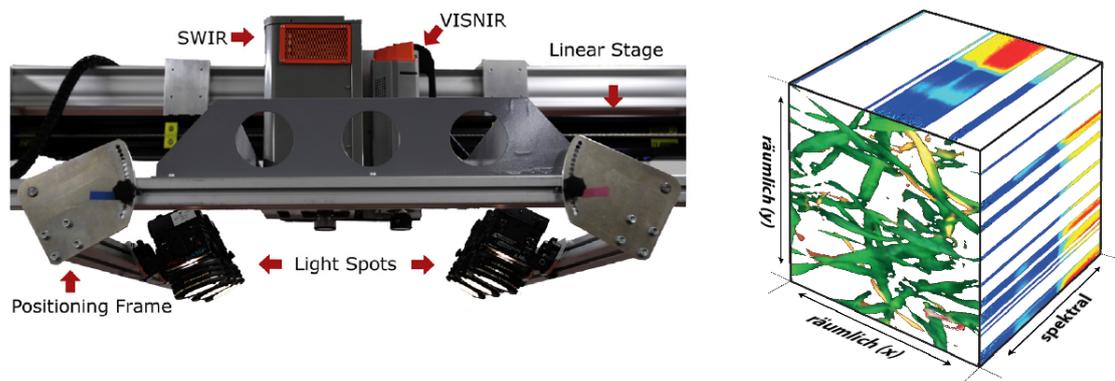


Abbildung 2.1: Hyperspektrales Kamerasystem der Pushbroom-Bauform (links). Es besteht aus zwei Kameras, die an einer linearen Verschiebeeinrichtung befestigt sind. Rechts ist ein Hyperspektralbild einer Gerstenpflanze als sogenannter Hypercube mit zwei räumlichen und einer spektralen Achse dargestellt (modifiziert aus Behmann et al., 2015a)

Diese sowohl spektral, als auch räumlich hohe Auflösung wird für die Stressdetektion benötigt. Im spektralen Bereich ist sie erforderlich, da die relevanten Merkmale häufig unbekannt sind und bei einer zu geringen Abtastrate das Risiko besteht, wichtige Wellenlängen nicht zu beobachten. Räumlich wird sie benötigt, um den Anteil der Mischpixel von Blatt und Hintergrund und gleichsam die minimale Größe eines noch detektierbaren Phänomens zu reduzieren.

Die von Hyperspektralkameras gemessene reflektierte Lichtintensität ist zwischen verschiedenen Messaufbauten und Messtagen nicht übertragbar, da diese sowohl von Sensorcharakteristiken, als auch von der spezifischen Beleuchtungssituation auf dem jeweiligen Blatt abhängt. Für verlässliche Analyseergebnisse und übertragbare Modelle ist es erforderlich aus dieser die beleuchtungsunabhängige Reflektanz zu berechnen. Dies ist ein nicht-trivialer

Vorgang, der sowohl eine radiometrische Normierung der Bilder anhand eines Reflektanznormals, als auch eine spektrale Kalibrierung der Hyperspektralkamera umfasst. Bei der radiometrischen Normierung wird die Beleuchtungsstärke bei jeder Messung erfasst und genutzt, um aus der Intensität des reflektierten Lichts die lokale Reflektanz zu berechnen. Die spektrale Kalibrierung der Kamera wird hingegen in größeren Zeitintervallen durchgeführt. Dabei wird durch die Beobachtung von Licht einer bekannten Wellenlänge die Abweichung der gemessenen Wellenlänge von der Referenz bestimmt und gegebenenfalls korrigiert. Unter der Bedingung, dass die Blätter in Position und Ausrichtung mit dem Reflektanznormal übereinstimmen, lassen sich zuverlässig Reflektanzen herleiten. Bei Abweichungen von diesen idealen Bedingungen, wie sie bei höheren Pflanzen unweigerlich auftreten, verbleiben durch die Pflanzengeometrie Artefakte in den Reflektanzdaten.

Falls die Bilddaten geometrisch analysiert oder räumlich mit anderen Daten in Bezug gesetzt werden sollen, ist über die radiometrische Normierung und spektrale Kalibrierung hinaus eine geometrische Kalibrierung der Kamera erforderlich. Dabei werden die geometrischen Abbildungseigenschaften der Kamera und somit die den einzelnen Pixeln zugeordneten Raumstrahlen bestimmt. Für eine erfolgreiche Kamerakalibrierung muss das Modell der Abbildungseigenschaften zur Bauform der Kamera passen. Verschiedene Bauformen für Hyperspektralkameras wurden entwickelt, die jeweils unterschiedliche Stärken und Schwächen haben. Man unterscheidet sogenannte Whiskbroom-Kameras, die einzelne Pixel nacheinander abtasten und Pushbroom-Kameras, die eine ganze Bildzeile zeitgleich beobachten (siehe Abb. 2.1). Weitere Bauformen umfassen den Bildaufbau aus einer Folge spektraler Bänder durch einen einstellbaren optischen Filter und das „snapshot imaging“, das die Reflektanzeigenschaften des gesamten Bildes zeitgleich beobachtet (Bareth et al., 2015). Snapshot-Kameras haben keine beweglichen Teile, dafür aber auch häufig nur eine geringe räumliche Auflösung, wohingegen die Kameras mit spektralem Filter durch die aufeinanderfolgende Beobachtung der Bänder auf einen zumindest kurzzeitig stabilen Standpunkt angewiesen sind.

Für die Analyse pflanzen-physiologischer Eigenschaften im Nahbereich werden häufig Pushbroom-Kameras eingesetzt, da sie eine hohe räumliche mit einer hohen spektralen Auflösung kombinieren. Ihr Nachteil besteht im aufwändigen Messaufbau mit mechanisch bewegten Teilen. Ihr Messprinzip unterscheidet sich jedoch deutlich von dem der RGB-Kameras, die gut durch das Modell einer Lochkamera beschrieben werden können. Mit einer Pushbroom-Kamera werden zu einem Zeitpunkt die spektralen Eigenschaften einer Bildzeile beobachtet und das Hyperspektralbild durch mechanisches Verschieben der Kamera bzw. des Objekts aufgebaut. Folglich hat eine Pushbroom-Kamera statt eines Projektionszentrums ein Geradenstück im 3D-Raum. Innerhalb einer Bildzeile wird eine perspektivische Abbildung durchgeführt, wohingegen in Bewegungsrichtung eine Parallelprojektion erfolgt.

Die spektrale Auflösung der verwendeten VISNIR-Kamera ImSpector V10E beträgt ca. 3nm, die der SWIR-Kamera ImSpector N25E ca. 10nm (Spectral Imaging Ltd., Finnland). Die Pixelgröße auf dem Objekt ist in erster Linie abhängig vom Abstand der Pflanze, beträgt aber in einer üblichen Messdistanz von 60cm für die VISNIR-Kamera ca. 0,2mm und für die SWIR-Kamera ca. 1mm.

Eine geometrische Kalibrierung hyperspektraler Pushbroom-Kameras für die Pflanzen-Phänotypisierung wurde bisher im Nahbereich nicht durchgeführt. Dies kann dadurch be-

gründet sein, dass geometrische Analysen hyperspektraler Bilder allenfalls eine untergeordnete Rolle spielen. Andererseits könnte die Kalibrierung auch dadurch erschwert werden, dass die Bauformen der Hyperspektralkameras von denen der „normalen“, perspektivischen RGB-Kameras deutlich abweichen und folglich weit verbreitete Programme zur Kalibrierung nicht anwendbar sind. Für die Verknüpfung mit Pflanzengeometrie besitzt die geometrische Kalibrierung jedoch eine hohe Relevanz.

2.1.2 Geometriesensoren

Die Untersuchung der geometrischen Störgrößen im hyperspektralen Signal erfordert Informationen über die Pflanzengeometrie mit einer räumlichen Auflösung, die der Skala der Effekte entspricht. In Abhängigkeit von der Rauheit der beobachteten Blätter, die z.B. zwischen Gerste und Zuckerrübe sehr unterschiedlich ist, kann dies von einem Zentimeter bis in den Submillimeterbereich gehen. Neben der Detailliertheit der Oberfläche sind jedoch Unstetigkeiten, wie sie an Blatträndern, aber auch Knicken innerhalb eines Blattes auftreten können, die bestimmenden Faktoren für die benötigte Erfassungsgüte. Um die Kanten den Pixeln zuordnen zu können, ist eine Messung der Pflanzenarchitektur mit einer räumlichen Auflösung, die mindestens der Auflösung der hyperspektralen Kamera entspricht, erforderlich. Dies erlaubt dann die Berechnung von 3D-Merkmalen, wie Blattneigung und Höhe, die einzelnen Pixeln zugeordnet werden können.

Bei der Erfassung der Form von Pflanzen treten aus geodätischer Sicht folgende Probleme auf: Zum einen können Pflanzenoberflächen nicht gut durch geometrische Primitive approximiert werden, sondern die Geometrien der einzelnen Zellen erzeugen eine raue Oberfläche mit hoher Komplexität. Darüber hinaus limitiert die Messdauer die Genauigkeit, da Bewegungen der Pflanze in Folge von Luftzug oder Eigenbewegungen, z.B. durch Ausrichtung der Blätter zur Lichtquelle, auftreten. Eine konsistente Messung muss folglich so schnell durchgeführt werden, dass diese Bewegungen nur eine untergeordnete Rolle spielen. Häufig erschwert zudem die komplexe und sich selbst verdeckende Geometrie des Blattwerks eine vollständige Erfassung der Pflanzenarchitektur.

Bei derartigen Messobjekten, die Messdistanzen von wenigen Zentimetern bedingen, liefern Nahbereichslaserscanner nach dem Triangulationsverfahren die genauesten Ergebnisse. Die alternativen Distanzmesstechniken, Laufzeit- und Phasenvergleichsverfahren, erreichen keine vergleichbaren Genauigkeiten auf diese kurze Distanz. Aufgrund des geringen Messbereichs der Nahbereichslaserscanner werden zur verdeckungsfreien und somit vollständigen Geometrieerfassung mehrere Standpunkte benötigt. Ein möglicher Ansatz sind Messarme, die die Sensorposen mit hoher Genauigkeit erfassen und die verschiedenen Standpunkte miteinander verknüpfen. Gegenüber der Verknüpfung verschiedener Beobachtungspositionen über Passpunkte bietet dies einen enormen Vorteil in der Messgeschwindigkeit, welche, wie erläutert, eng mit der Konsistenz der Messung verknüpft ist. Ein bedeutendes Hindernis für den Einsatz der Kombination aus Nahbereichslaserscanner und Messarm, stellen häufig die Investitionskosten dar. Systeme aus der Industrievermessung kosten ca. 100.000 €.

Da in den letzten Jahren Low-Cost-Sensoren zur Geometrieerfassung verfügbar geworden sind, haben wir in Paulus et al. (2014a) ihr Potential zur Phänotypisierung von Nutzpflanzen untersucht. Ziel war es, zu überprüfen, ob derartige Investitionen in Industriemesssysteme

wirklich nötig sind und in welchen Situationen auf kostengünstige Alternativen zurückgegriffen werden kann. Dazu wurden die Sensorsysteme Microsoft Kinect (Khoshelham und Elberink, 2012) und das David-System (Winkelbach et al., 2006) anhand von drei ausgewählten Phänotypisierungsobjekten bewertet. Beide Systeme arbeiten nach dem Triangulationsprinzip, wobei die Kinect ein Tiefenbild zu einem Zeitpunkt erstellt und beim David-System das Tiefenbild mittels einer Laserlinie abgetastet wird. Die Kinect und das David-System wurden mit einem Industriemesssystem bestehend aus dem Laserscanner Perceptron V5 und dem Romer Infinite 2.0 Messarm verglichen, welches aufgrund der übergeordneten Genauigkeit als Referenz diente. Die untersuchten Szenarien umfassten die Messung der Oberflächen und Volumen von Zuckerrüben, der Blattflächen junger Zuckerrüben-Pflanzen, sowie der Volumen und Längen von Weizenähren (vgl. Abb. 2.2). Die Experimente zeigen, dass die Low-Cost-Sensoren für die beschriebenen Anwendungsszenarien durchaus geeignet sind, wobei die begrenzte Detailauflösung und die Glättung limitierende Faktoren sind. Im direkten Vergleich war die Kinect besser für die Erfassung von glatten Oberflächen geeignet, da die interne Signalverarbeitung die Objekte vereinfacht. Das David-System hingegen löste auch kleine Details wie einzelne Körner an den Weizenähren besser auf, dafür stellte hier die Vollständigkeit des 3D-Modells häufig ein großes Problem dar.

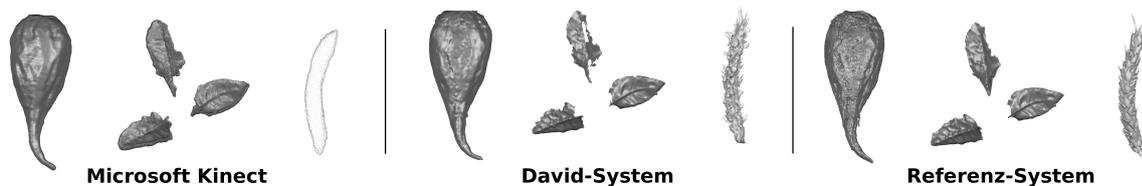


Abbildung 2.2: 3D Modelle der pflanzlichen Organe Zuckerrübe, Zuckerrübenblätter und Weizenähre (von links nach rechts). Zwei Low-Cost Sensoren (Microsoft Kinect und David-System) werden mit einem qualitativ übergeordneten Referenzsensor verglichen (modifiziert aus Paulus et al., 2014a).

Zusammenfassend konnte festgestellt werden, dass die Low-Cost-Sensoren für viele Aufgaben aus dem Bereich der Phänotypisierung geeignet sind und aufgrund ihres geringen Preises das Potential besitzen, die 3D-Phänotypisierung von Nutzpflanzen weiter zu verbreiten. Im Gegensatz zu den Industriesystemen besitzen beide Low-Cost-Systeme jedoch individuelle Schwächen, sodass ein universeller Einsatz zur Zeit noch nicht realistisch erscheint. Insbesondere Bereiche mit starker Krümmung wurden durch Glattheitsannahmen geglättet, obwohl gerade dort die stärksten optischen Effekte auf das hyperspektrale Signal erwartet werden. Kommende Generationen derartiger Low-Cost-Sensoren besitzen aber eine höhere Auflösung und lassen auch höhere Distanzmessgenauigkeiten erwarten. Daher muss davon ausgegangen werden, dass in Zukunft die 3D-Erfassung von Pflanzen in für die Forschung geeigneter Auflösung und Genauigkeit auch mit Low-Cost-Sensoren erreicht werden kann.

Hier wurde für die Erstellung der 3D-Pflanzenmodelle von Zuckerrüben jedoch noch auf das Referenzsystem mit übergeordneter Genauigkeit bestehend aus Perceptron V5 Laserscanner in Kombination mit dem Romer Infinite 2.0 Messarm zurückgegriffen (Paulus et al., 2014b). Dieses Messsystem erreicht eine Genauigkeit von unter 0.1mm bei einer Auflösung von bis

zu 14µm in einem sphärischen Messbereich mit 2.8m Durchmesser, womit die erfassten Geometriemodelle für die vorgestellten Hyperspektralkameras geeignet sind.

2.1.3 Modellierung der Abbildungseigenschaften hyperspektraler Kameras

Die beiden vorgestellten Sensortypen messen in jeweils sensorfesten Koordinatensystemen, die Hyperspektralkamera in der 2D-Bildebene und der 3D-Laserscanner in einem 3D-Koordinatensystem mit dem Referenzpunkt des Messarms als Ursprung. Zur Untersuchung der geometrischen Effekte im hyperspektralen Signal müssen beide Datentypen in einem konsistenten Koordinatensystem kombiniert werden. Die Zuordnung von Geometrie und Hyperspektralbild soll dabei auf Ebene der einzelnen Pixel erfolgen, um einen Informationsverlust durch eine Skalierung auszuschließen. Die Eigenschaften der Messdaten spezifizieren dabei die genaue Rolle der Referenzierung und die Anforderungen an die Referenzierungsgenauigkeit. Zur Unterscheidung der einzelnen Paramertypen wird diese Notation hier und im Folgenden verwendet: Skalare werden durch Kleinbuchstaben und Normalschrift, Vektoren durch Kleinbuchstaben und Fettschrift und Matrizen durch Großbuchstaben und Fettschrift gekennzeichnet.

Die Geometrie der Pflanze ist in Form einer triangulierten Punktwolke durch 3D-Koordinaten $\mathbf{x} = [x, y, z]^T$ im lokalen Koordinatensystem des Laserscanners gegeben. Aufgrund der überlegenen Messgenauigkeit des Systems, wird die Genauigkeit dieser Punkte als übergeordnet angesehen, weshalb sie hier als abweichungsfreie, nicht-stochastische Größen behandelt werden. Das Hyperspektralbild wird von einem 2D-Koordinatensystem aufgespannt. Die Bildkoordinaten werden durch (u, v) , bzw. in homogener Koordinatenform $\mathbf{x}' = [wu, wv, w]^T$ definiert, wobei u die Position innerhalb einer Bildzeile angibt und v die Position in Bewegungsrichtung der Kameras. Die Abstände der Pixel auf dem Messobjekt liegen im Bereich von einigen Millimetern bis in den Submillimeterbereich. Für hinreichend geringe Abweichungen bei der Zuordnung von Geometrie und Bildpunkt wird die Referenzierung in Subpixel-Genauigkeit benötigt.

Die Bestimmung dieses Abbildungsmodells erfolgt durch die geometrische Kalibrierung, wobei jedem Pixel eine Halbgerade im 3D-Objektraum zugeordnet wird. Alle Punkte auf diesem Strahl werden durch die Kameraoptik auf den zugeordneten Pixel abgebildet. Die geometrische Kalibrierung hat insbesondere in der Photogrammetrie eine lange Geschichte (Clarke und Fryer, 1998). Die Lochbildkamera ist das am häufigsten angewendete Kameramodell. Dieses lineare Modell beschreibt eine Kamera mit perspektivischen Abbildungen in beiden Koordinatenrichtungen. Dabei gibt es eine strikte Trennung von inneren und äußeren Kameraparametern.

$$\mathbf{x}' = \begin{bmatrix} wu \\ wv \\ w \end{bmatrix} = M\mathbf{x} = M \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (2.1)$$

$$M = KR [I | -\mathbf{t}] \quad (2.2)$$

Die inneren Kameraparameter, wie Kamerakonstante, Hauptpunkt und Maßstab, repräsentieren die konstanten Abbildungseigenschaften, die unabhängig von der aktuellen Pose der

Kamera sind. Sie bilden die Kalibriermatrix K . Die äußeren Kameraparameter geben über Position \mathbf{t} und Ausrichtung R die äußere Orientierung der Kamera an. I ist eine 3×3 Einheitsmatrix. In homogenen Koordinaten ist das Kameramodell vollständig durch eine 3×4 Projektionsmatrix M definiert.

Die Bilder der Pushbroom-Kamera hingegen sind das Ergebnis einer Parallelprojektion in Bewegungsrichtung der Kamera und einer perspektivischen Abbildung innerhalb einer Bildzeile (Abb. 2.3). Ausgehend vom Punkt \mathbf{t} wird dort eine Zeilenkamera entlang des Vektors \mathbf{v} verschoben und somit die Bildebene aufgespannt. Eine Repräsentation dieser Abbildungseigenschaften mit rein perspektivischen Modellen ist daher ausgeschlossen.

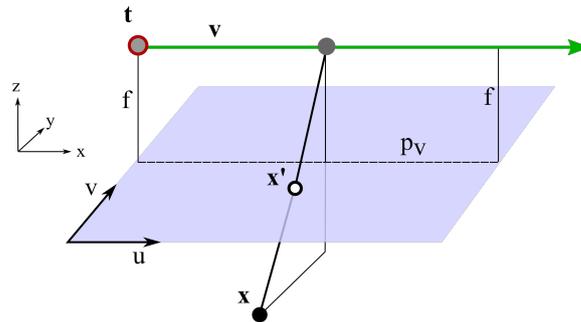


Abbildung 2.3: Abbildungsgeometrie der linearen Pushbroom-Kamera (modifiziert aus Behmann et al., 2015b).

Die Kalibrierung der linearen Pushbroom-Kamera, die eine linear bewegte Zeilenkamera darstellt, wurde von Gupta und Hartley (1997) eingeführt. Dieses Modell orientiert sich stark an der Struktur der Lochbildkamera, jedoch ist eine strikte Trennung von äußeren und inneren Parametern nicht mehr möglich. Grund dafür ist die Parallelabbildung in Bewegungsrichtung der Kamera. Diese koppelt Kamerabewegung und Abbildungseigenschaften direkt miteinander (siehe Formel (2.4)).

$$\mathbf{x}' = \begin{bmatrix} u \\ wv \\ w \end{bmatrix} = M\mathbf{x} = M \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (2.3)$$

Dementsprechend ist der Bildpunkt \mathbf{x}' durch teilweise homogene Koordinaten gegeben, wobei der erste Koordinateneintrag u nicht homogen und der zweite Koordinateneintrag $[wv]$ homogen ist. Folglich verknüpft auch eine teilweise homogene Projektionsmatrix M den 3D-Objektpunkt \mathbf{x} mit dem Bildpunkt \mathbf{x}' .

Nach Schätzung von M durch eine Direkte Lineare Transformation (DLT, Abdel-Aziz und Karara, 1971), können die einzelnen Kameraparameter aus dieser bestimmt werden. In diesem Punkt unterscheidet sich das Vorgehen deutlich von der Lochbildkamera. Da sich die Projektionsmatrix M aus der Position zu Beginn der Messung \mathbf{t} und der Kalibriermatrix K folgendermaßen zusammensetzt: $M = [K | -K\mathbf{t}]$, lassen sich \mathbf{t} und K direkt aus M herleiten.

$$K = LR = \begin{bmatrix} 1/v_x & 0 & 0 \\ -k(fv_y + p_v v_z)/v_x & kf & kp_v \\ -kv_z/v_x & 0 & k \end{bmatrix} R \quad (2.4)$$

K kann daraufhin in L und R aufgespalten werden, indem durch die Multiplikation von K mit Rotationsmatrizen an den definierten Stellen der Matrix L der Wert 0 erzeugt wird. Das Produkt dieser Rotationsmatrizen bildet R . R repräsentiert, wie bei der Lochbildkamera, die Ausrichtung und L enthält die weiteren Parameter: den Bewegungsvektor \mathbf{v} , Brennweite f und Hauptpunkt p_v . Der Parameter k ist frei wählbar und repräsentiert die homogenen Eigenschaften der letzten beiden Zeilen von M . Zur Bestimmung der Parameter wird $k = 1$ fixiert.

Wie in der Dekomposition von L in Formel (2.4) sichtbar, sind die inneren Kameraparameter eng mit dem Bewegungsvektor \mathbf{v} verknüpft. Folglich sieht dieses Modell keine unabhängige Bestimmung von inneren und äußeren Parametern vor.

Das von Gupta und Hartley (1997) eingeführte Modell hat eine feste Parameteranzahl und erlaubt durch die bekannten Kameraparameter eine Plausibilitätskontrolle. Basierend auf korrespondierenden Punkten ist eine numerisch stabile Lösung für die Parameter verfügbar.

Modellgrenzen durch Linearitätsannahme

Entworfen wurde das Modell der linearen Pushbroom-Kamera in erster Linie für Fernerkundungssensoren wie satellitengestützte Kameras. Im hier untersuchten Nahbereich treten jedoch nicht-lineare Effekte in einer nicht tolerierbaren Größenordnung auf. Gründe hierfür liegen vermutlich vor allem in translatorischen und rotatorischen Abweichungen der mechanischen Verschiebung. Sowohl Änderungen der Geschwindigkeit, als auch geringe Winkeländerungen orthogonal zur Bewegungsachse beeinflussen die Geometrie der Abbildung. Eine Winkelabweichung von 0.1° führt beispielsweise bereits zu einer Verschiebung um mehrere Pixel. Wie später in Kapitel 3.2 gezeigt wird, sind die Abweichungen der verwendeten, realen hyperspektralen Kameras vom linearen Kameramodell signifikant und führen daher zu Rückprojektionsfehlern in einer Größenordnung von bis zu 10px. Folglich ist das lineare Modell nicht direkt für die Referenzierung von Hyperspektralbildern und 3D-Punktwolken in der benötigten Genauigkeit geeignet. Modelliert werden dort ausschließlich die linearen Eigenschaften der Kamera. Nicht-lineare Verzerrungen hingegen werden nicht modelliert und können sogar die Bestimmung der linearen Parameter verfälschen.

Aus diesem Grund werden die kombinierten, nicht-linearen Verzerrungsphänomene erfasst und durch 2D-Tschebyschow-Polynome ihre räumliche Verteilung modelliert. Erst durch diese Modellerweiterung zur Anpassung an die spezielle Situation des Nahbereichs werden die Abbildungseigenschaften mit Subpixel-Genauigkeit beschreibbar und die Referenzierung spektraler Information und 3D-Geometrie der Pflanzen mit dieser Genauigkeit möglich.

2.2 Ausgewählte Methoden zur Interpretation hyperspektraler Daten

Eine zentrale Rolle bei der Verbesserung der automatischen Stressdetektion basierend auf Signalen moderner Sensoren spielt die Datenauswertung. Erst in den letzten Jahren werden Methoden des maschinellen Lernens verstärkt in der Präzisionslandwirtschaft eingesetzt, wohingegen hyperspektrale Bilder seit Jahrzehnten verfügbar sind. Von Behmann et al. (2014a) wurde im Journal *Precision Agriculture* untersucht, in welchem Umfang Methoden des maschinellen Lernens in der Präzisionslandwirtschaft eingesetzt werden und welche Eigenschaften für ihren Erfolg verantwortlich sind. Klassisch kamen und kommen immer noch spektrale Vegetationsindizes (VI) zur Datenanalyse zum Einsatz (vgl. Kapitel 1). Durch die Kombination weniger ausgewählter Wellenlängen sind sie spezifisch für einen Parameter anhand eines Datensatzes entwickelt worden.

Methoden des maschinellen Lernens kombinieren daher häufig eine Vielzahl von spektralen Merkmalen zu gut generalisierenden Modellen. In der Merkmalsselektion werden aus den Rohdaten möglichst informationsreiche Merkmalsgruppen gewonnen (siehe Abb. 2.4). Die verwendeten spektralen Merkmale können sowohl einzelne Wellenlängen, Vegetationsindizes oder auch komplexere Funktionen sein. Die Merkmalsextraktion ist der erste Schritt bei der Datenanalyse durch Methoden des maschinellen Lernens (Kapitel 2.2.3). VIs stehen hier, falls sie als Merkmal genutzt werden, am Anfang des Analyseprozesses und nicht am Ende.

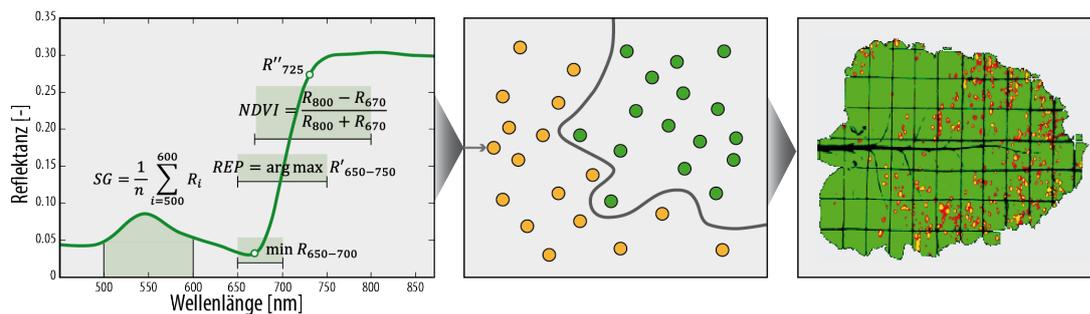


Abbildung 2.4: Schema einer Klassifikation hyperspektraler Daten (von links nach rechts) ausgehend von spektralen Merkmalen durch einen nicht-linearen, diskriminativen Klassifikator zu einer pixelweisen Prädiktion von Krankheits-symptomen (modifiziert aus Behmann et al., 2014a).

Es gibt zwei Hauptgründe, warum Methoden des maschinellen Lernens für die Analyse hyperspektraler Daten verstärkt eingesetzt werden. Erstens sind die statistischen Verteilungen hyperspektraler Daten für die Prädiktion von Stresssymptomen unbekannt. Viele herkömmliche Verfahren basieren jedoch auf Annahmen über statistische Eigenschaften, die, falls sie nicht erfüllt sind, die Qualität des Ergebnisses signifikant beeinträchtigen. Viele Methoden des maschinellen Lernens basieren nicht auf harten Annahmen, sondern sind in der Lage relevante Informationen aus Daten abzuleiten, sogar wenn das zugrunde liegende Verteilungsmodell der Daten unbekannt ist (Breiman, 2001). Dabei wird die benötigte Modellkomplexität und die Anzahl Modellparameter während des Lernprozesses implizit aus Trainingsdaten abgeleitet.

Zweitens ist ein Großteil der Variabilität hyperspektraler Daten ein Effekt der Störgrößen und nicht verknüpft mit dem untersuchten Stressprozess. Generative Verfahren modellieren jedoch die gesamten Eigenschaften der Daten $P(X)$ zur Bestimmung der Zielgröße Y , beispielsweise mittels des Bayes-Theorems $P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)}$. Somit wird ein Großteil des Modells durch die Effekte in den Trainingsdaten X , die nicht mit der Zielgröße verknüpft sind, bestimmt. Diskriminative Verfahren sind in derartigen Situationen effizienter, da nur die für die Bestimmung der Zielgröße relevanten Dateneigenschaften $P(Y|X)$, bzw. eine entsprechende Diskriminante direkt modelliert werden und daher kein Modell der gesamten Datenverteilung $P(X)$ benötigt wird (Lafferty et al., 2001). Dies führt zu kompakteren Modellen, die performanter gelernt und angewendet werden können und zudem weniger Trainingsdaten benötigen.

Ein erfolgreicher Ansatz zur Datenanalyse unter Nutzung des maschinellen Lernens kombiniert Methoden auf verschiedenen Ebenen. Basierend auf einem unüberwachten Ansatz zum Labeln der Trainingsdaten (Kapitel 2.2.1), wurde ein ordinales Klassifikationsmodell (Kapitel 2.2.2) für die frühzeitige Detektionen des Stressprozesses entwickelt. Durch die Diskretisierung des Stressprozesses können nun Merkmalsgruppen selektiert werden, die optimal für die Modellierung der Prozessstufen geeignet sind (Kapitel 2.2.3). Innerhalb des ordinalen Klassifikationsmodells werden Support Vektor Maschinen (SVM) als Basisklassifikator verwendet (Kapitel 2.2.4). Dieses Prädiktionsmodell ist besonders für hyperspektrale Daten geeignet, da sie eine besonders gute Generalisierungsfähigkeit auch bei dünn besetzten, hochdimensionalen Merkmalsräumen erzielen.

2.2.1 Unüberwachtes Labeln eines ordinalen Prozesses

Das bereits in der Einleitung diskutierte Problem der unsichtbaren Symptome im Frühstadium des Trockenstresses führte zu der Entwicklung eines unüberwachten Ansatzes zur Erzeugung der benötigten ordinalen Label. Zwar sind manuelle Annotationen besonders vitaler und gestresster Pflanzenteile durchführbar, jedoch erfassen sie den Übergang von vital zu gestresst nur unzureichend. Der hier gewählte Ansatz bestimmt erst nominale Label und überführt sie in einem zweiten Schritt zu ordinalen Labeln. Diese ordinalen Label ergänzen die nominalen Label durch eine natürliche Ordnung, die hier durch die Kombination zweier Vegetationsindizes zur Stressdetektion eingeführt wird.

Dazu wird zuerst mit einem unüberwachten Verfahren der Clusteranalyse die Gesamtheit aller Reflektanzspektren in Gruppen mit homogenen spektralen Eigenschaften segmentiert. Die gewonnenen Clusterzugehörigkeiten stellen nominale Label dar. Entscheidend für den Übergang zu ordinalen Labeln war die Feststellung, dass alle Datenpunkte eines Clusters einen vergleichbaren Stresszustand besitzen und sich dieser zwischen den Extremen vital und seneszent einordnen lässt. Aufgrund fehlender Distanzmaße ist eine direkte Bewertung des einzelnen Clusters nicht möglich, jedoch lässt sich durch Vergleiche eine Reihenfolge definieren. Diese Reihenfolge der nominalen Label erfasst als ordinale Ordnung den Prozess von vital zu gestresst detaillierter, als dies durch eine manuelle Annotation der sichtbaren Klassen möglich wäre.

Zur Clusteranalyse wurde der etablierte k-Means Algorithmus genutzt, der die zentralen Spektren der einzelnen Cluster bestimmt und zusätzlich jedem Datenpunkt ein Cluster

zuordnet. Die Ordnung der Cluster wurde durch die Kombination der stress-sensitiven VIs „Modified Red Edge Normalized Difference Vegetation Index“ (mRENDVI, Datt, 1999) und „Plant Senescence Reflectance Index“ (PSRI, Merzlyak et al., 1999) auf den zentralen Spektren eindeutig ermittelt. Ergebnis des Ansatzes war eine Zuordnung ordinaler Label zu den einzelnen Pixeln, die auch unsichtbare Differenzen der frühen Formen der Stressreaktion abbildet.

2.2.2 Ordinale Klassifikation

Aufbauend auf diesen ordinalen Labeln wird ein ordinales Klassifikationsmodell für den fortschreitenden Stressprozess gelernt. Das ordinale Modell ist durch die ordinalen Klassen im Gegensatz zu generischen Klassifikationsansätzen an die Struktur des Stresses im Merkmalsraum angepasst. Generische Verfahren zur Mehrklassen-Klassifikation würden die Trennfunktionen zwischen allen Stufen des Stressprozesses bestimmen, wohingegen der ordinale Ansatz nur die für den ordinalen Prozess notwendigen Trennfunktionen bestimmt.

Die Klassen sind ordinal, d.h. eindimensional und linear geordnet, wobei die Nachbarschaftsbeziehungen innerhalb der Ordnung auch auf den Merkmalsraum übertragbar sind. Die lineare Ordnung korrespondiert dabei mit der Regression, die jedoch einen kontinuierlichen Wert prädiziert, und die diskreten Klassen entsprechen den Prädiktionen der Klassifikation. Damit ordnet sich die ordinale Klassifikation als Prädiktionsverfahren zwischen Klassifikation und Regression ein.

Für Datensätze mit ordinalen Zielgrößen kann durch die Verwendung entsprechender Modelle die Effektivität des Prädiktionsvorgangs gegenüber generischen Verfahren gesteigert werden. Dabei werden wichtige Bereiche betont und nicht benötigte Aspekte aus dem Modell entfernt. Angepasste Modelle sind gegenüber generischen Verfahren kompakter, benötigen weniger Trainingsdaten oder besitzen eine höhere Prädiktionsgenauigkeit (Agresti, 2002; Behmann et al., 2014b). Zur ordinalen Klassifikation wurden mehrere Ansätze entwickelt, die jeweils generische Verfahren adaptieren, z.B. die ordinale logistische Regression (Williams, 2006), die Support Vector Ordinal Regression (Chu und Keerthi, 2007) und ordinale Klassifikation nach Frank und Hall (2001).

Eine Anwendung der ersten beiden Verfahren für die Klassifikation der Stresstufen auf die untersuchten Datensätzen war jedoch aus folgenden Gründen nicht erfolgreich: Beide Verfahren bilden die Merkmale mit einer globalen Funktion auf eine kontinuierliche Variable ab. Erst in einem zweiten Schritt werden mittels Schwellwerte die ordinalen Klassenzugehörigkeiten gewonnen. Sie bestimmen sehr kompakte Modelle, die durch diesen Ansatz aber die Parallelität aller Klassengrenzen im Merkmalsraum erzwingen. Infolgedessen sind sie auch nur auf Daten anwendbar, die sich durch parallele Trennfunktionen sinnvoll klassifizieren lassen.

Die verwendete ordinale Klassifikation modelliert die Klassengrenzen zwischen benachbarten Klassen und entkoppelt die einzelnen Trennfunktionen vollständig voneinander (Frank und Hall, 2001). Statt ein globales Klassifikationsmodell zu lernen, wird hier die Aufgabe auf mehrere dichotome Klassifikationsmodelle verteilt. Diese Klassifikationsmodelle können sich nun auch auf jeweils individuelle Merkmalsräume beziehen. Dass Trennfunktionen zwischen

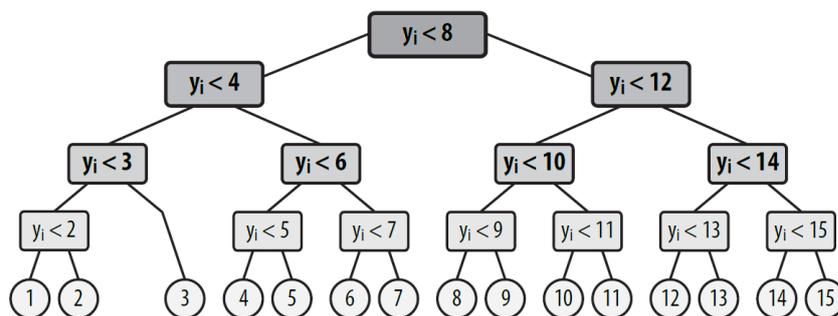


Abbildung 2.5: Hierarchie der Klassifikation durch die ordinale Klassifikationsstruktur (Behmann et al., 2014c).

nicht benachbarten Klassen nicht modelliert werden, bedeutet bei den vorliegenden Daten keine Einschränkung der Prädiktionsgenauigkeit, da diese Klassen im Merkmalsraum nicht direkt benachbart sind. Ihre Separierung ergibt sich aus anderen Trennfunktionen. Beispielsweise kann die Separierung der Klassen 1 und 3 auch durch die Trennfunktionen zwischen den Klassen 1 und 2, sowie 2 und 3 erfolgen. Um eine Eindeutigkeit zu erreichen, muss eine zusätzliche Hierarchie der Klassen aufgestellt werden (siehe Abb. 2.5). In dieser Struktur eines binären Baumes wird die Reihenfolge, in welcher die einzelnen Prädiktionsfunktionen für einen Merkmalsvektor evaluiert werden, festgelegt. Für eine Prädiktion müssen hier nicht alle Trennfunktionen ausgewertet werden. Analog zu einem ausgeglichenen binären Suchbaum werden ausgehend von der Wurzel die Trennfunktionen ausgewertet, bis die Zielklassen in den Blättern des Baumes erreicht sind. Die asymptotische Komplexität der Klassifikation mit n Klassen reduziert sich dadurch auf $\log(n)$, was im Vergleich mit generischen Mehrklassenansätzen wie one-vs.-one (n^2) oder one-vs.-all (n) deutlich geringer ist.

In die konkrete Ausgestaltung der Hierarchie können Vorinformationen über die kritischen Trennfunktionen einbezogen werden. Sichere und somit weniger fehleranfällige Prädiktionsfunktionen sollten möglichst früh und die unsicheren Prädiktionen möglichst in den letzten Schritten durchgeführt werden. Bei einer Fehlklassifikation im letzten Schritt kann nur eine direkt benachbarte Klasse prädiziert werden, was die Auswirkungen auf das Gesamtergebnis deutlich reduziert.

Das beschriebene ordinale Klassifikationsverfahren hat starke Anlehnung an die Support Vector Ordinal Regression, lockert jedoch die straffe Bedingung, dass die Trennfunktionen im Merkmalsraum parallel sein müssen. Die Lockerung dieser Einschränkung erhöht die Flexibilität des Modells und erweitert den Anwendungsbereich. Als dichotomes Klassifikationsverfahren werden hier lineare Support Vektor Maschinen (Kapitel 2.2.4) in den inneren Knoten des Baumes verwendet. Der Einsatz nicht-linearer SVMs wurde geprüft, jedoch ermöglichten sie auf den untersuchten Daten keine Steigerung der Genauigkeit. In der Folge wird dieses Klassifikationsmodell als ordinale SVM bezeichnet.

Die einzelnen Klassifikationsmodelle werden unabhängig voneinander trainiert und können daher auch auf unterschiedlichen Merkmalskompositionen basieren. Im nächsten Kapitel

wird gezeigt wie diese Eigenschaft für kompaktere Klassifikationsmodelle genutzt werden kann.

2.2.3 Merkmalsselektion

Die Zusammensetzung des Merkmalsraums bestimmt welche Eigenschaften des hyperspektralen Signals in die Prädiktion einbezogen werden. Dies ist entscheidend für die Prädiktionsqualität und die Komplexität des Problems. Im Falle von hyperspektralen Daten können vielfältigste Merkmale berechnet werden, die die Charakteristiken der Spektren mit unterschiedlichen Methoden parametrisieren. Am etabliertesten sind die VI, die über eine mathematische Formel einige wenige Bänder mit einem physiologischen Parameter verknüpfen. Darüber hinaus kann die Form des Spektrums auch parametrisiert werden, wobei hier z.B. Polynome (Römer et al., 2011) oder Wavelet Transformationen (Bruce et al., 2002) eingesetzt werden können. Auch ist es auch möglich, die Reflektanz in den einzelnen Bändern direkt als Merkmale zu nutzen, wobei die Redundanz benachbarter Bänder hohe Korrelationen zwischen den Merkmalen begünstigt.

Ziel der Merkmalsextraktion und -selektion ist, ausgehend von einer initialen Merkmalsgruppe, die optimale Kombination von Merkmalen für das jeweilige Problem zu finden. Dabei muss diese Gruppe ein Maximum an Information über den analysierten Parameter, jedoch möglichst wenig Redundanz zwischen den Merkmalen besitzen. Zu wenig Merkmale führen zu geringen Prädiktionsgenauigkeiten, wenn jedoch zu viele Merkmale analysiert werden, steigt die Modellkomplexität ohne Steigerung der Genauigkeit. Die Prädiktionsgenauigkeit kann sogar sinken, wenn durch die implizite Merkmalsgewichtung der redundanten Merkmale relevante Informationen überdeckt werden. Anders ausgedrückt, nähern sich die Distanzen zwischen den Datenpunkten mit steigender Dimension des Merkmalsraums immer weiter an, sodass keine aussagekräftigen Modelle hergeleitet werden können (Fluch der hohen Dimensionen).

Vielfältige Verfahren wurden zu diesem Zweck in den letzten Jahrzehnten entwickelt, die sich in Wrapper, Filter und eingebettete („Embedded“) Ansätze gruppieren lassen (Guyon und Elisseeff, 2003). Filter-Verfahren nutzen häufig statistische Eigenschaften um Merkmale einzeln zu bewerten, wohingegen Embedded-Verfahren die während eines Lernprozesses gewonnenen Gewichte nutzen. Wrapper verwenden einen Prädiktionsalgorithmus, z.B. einen Klassifikator, um die kombinierte Relevanz einzelner Merkmalsgruppen zu bestimmen. Zu diesem Zweck wird mittels der zu bewertenden Merkmale ein Modell gelernt und dieses mittels Prädiktionsgüte auf Testdaten bewertet. Mit Hilfe einer Suchstrategie wird der Raum der Merkmalskombination systematisch nach der optimalen Merkmalskombination abgesehen. Etabliert sind hier sequenzielle Ansätze, die einer Greedy-Strategie folgen, aber auch genetische Algorithmen werden eingesetzt. Wrapper-Ansätze liefern häufig die genauesten Ergebnisse, da hier die Merkmale in Kombination mit dem später genutzten Prädiktionsalgorithmus bereits bewertet werden können und somit stärker an diesen angepasst sind. Außerdem wird die kombinierte Prädiktionsfähigkeit der Merkmalsgruppe statt der einzelnen Merkmale bewertet. Die hohe Genauigkeit geht einher mit einem hohen rechnerischen Aufwand durch das wiederholte Lernen und Bewerten des Modells.

Im Kontext des ordinalen SVM Modells steigt der Aufwand weiter, da hier die optimale Merkmalszusammensetzung für jede einzelne Trennfunktion gesucht wird. Bei n zu separierenden Klassen müssen folglich $n - 1$ Merkmalsgruppen optimiert werden. Belohnt wird der hohe Aufwand der Merkmalsselektion bei der ordinalen SVM mit sehr kompakten Merkmalsgruppen, da diese optimal an die jeweiligen Stufenübergänge des Modells angepasst sind. Ein globales Merkmalsset würde mehr Merkmale umfassen und einen Kompromiss aus den lokalen Anforderungen der einzelnen Stufen darstellen.

Eine Möglichkeit diesen Merkmalsselektionsansatz zu beschleunigen bilden approximative Modellbewertungsverfahren, wie der Span-Estimate, der in Kapitel 2.2.4 näher vorgestellt wird.

2.2.4 Support Vektor Maschinen und Span-Estimate

Support Vektor Maschinen (SVM) als prominentester Vertreter der Large Margin Methoden sind besonders gut für die Analyse hyperspektraler Daten geeignet. Als überwachter, diskriminativer und dichotomer Klassifikator bestimmt er anhand von annotierten Trainingsdaten die Trennfunktion, die unter Beachtung des Large Margin Kriteriums zwei Klassen optimal trennt (Cortes und Vapnik, 1995; Vapnik, 1998; Schölkopf und Smola, 2002).

Wie viele Methoden des maschinellen Lernens, macht dieses Verfahren keine starken Annahmen über die Art der Verteilungen der Klassen. Darüber hinaus besitzen sie jedoch die Eigenschaft besonders gut hochdimensionale Merkmalsräume zu nutzen und auch unter diesen Bedingungen dünnbesetzte und somit effizient prädizierende Modelle zu generieren. Beide Eigenschaften werden hier anhand der Optimierungsfunktion diskutiert.

Darüber hinaus sind SVMs als Large Margin Methoden eng mit der Theorie der strukturellen Risikominimierung verknüpft. Das strukturelle Risiko repräsentiert die Anfälligkeit einer Prädiktionfunktion für Überanpassung an die Trainingsdaten. Die Komplexität von Klassifikationsfunktionen wird hier durch ihre VC-Dimension abgeschätzt und ist eng verknüpft mit der Breite des Margins $\frac{1}{\|\mathbf{w}\|}$. Der Ansatz des maximalen Margin reduziert daher das Risiko einer Fehlklassifikation auf unbekanntem Testdaten. In der Optimierung wird die Hyperebene \mathbf{w} mit der Ursprungsdistanz b bestimmt, die einen maximalen Margin in Kombination mit minimalen Fehlern ξ_i besitzt. Für eine dichotome Klassifikation unter Berücksichtigung überlappender Klassen („Soft Margin“) mit den Merkmalsvektoren \mathbf{x}_i und den zugeordneten Klassen $y_i \in \{\pm 1\}$, ergibt sich für lineare SVMs folgendes Optimierungsproblem

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|_2^2 + C \sum_{i=1}^n \xi_i \quad (2.5)$$

unter den Nebenbedingungen

$$y_i(\mathbf{w} \cdot \mathbf{x}_i - b) \geq 1 - \xi_i, \quad \forall i. \quad (2.6)$$

Der Parameter C kontrolliert die Robustheit gegenüber Ausreißern, indem er den Strafterm für Fehlklassifikation skaliert. Dieser Wert muss an die Charakteristiken der jeweiligen

Datensätze angepasst werden. Im Fall der ordinalen SVM zeigt sich hier ein Vorteil: die Parameter der einzelnen Trennfunktionen können individuell optimiert werden und man ist nicht auf einen Kompromiss angewiesen, der bei deutlich unterschiedlichen Charakteristiken zwischen einzelnen Klassen zu einer reduzierten Prädiktionsgüte führt.

Nach Überführung des Minimierungsproblems in das duale Problem mit Hilfe von Lagrange-Multiplikatoren α_i und den Karush-Kuhn-Tucker-Bedingungen, ergibt sich die Optimierungsfunktion

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (2.7)$$

unter den Nebenbedingungen

$$1 \leq \alpha_i \leq C \text{ und } \sum_{i=1}^n \alpha_i y_i = 0, \forall i. \quad (2.8)$$

Anhand dieser Formel kann die Unabhängigkeit der Komplexität der Optimierung von der Dimension der Daten gezeigt werden. Die Datenpunkte gehen in Formel (2.7) ausschließlich in Form eines Skalarproduktes in die Optimierung ein. Dieses bestimmt die Affinität der Datenpunkte untereinander und führt aufgrund seiner Linearität zu linearen Trennfunktionen. Da das Skalarprodukt unabhängig von der Dimensionalität der Daten immer einen Skalar ergibt, ist auch die Optimierung losgelöst von der Datendimensionalität. Folglich sind SVMs, im Gegensatz zu vielen dichte-basierten Ansätzen, auch in der Lage effizient mit hochdimensionalen Datensätzen umzugehen. Die dichotome Entscheidungsfunktion für einen neuen Datenpunkt \mathbf{x} lautet

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b \right) \quad (2.9)$$

Hier zeigt sich, warum SVM Modelle als dünnbesetzt („sparse“) gelten. In Formel (2.9) werden für die Prädiktion nur die Datenpunkte mit einem $\alpha \neq 0$ benötigt. Diese Datenpunkte werden als Support Vektoren (SV) bezeichnet. In den meisten Fällen ist dies bei der linearen SVM nur ein sehr geringer Anteil der Datenpunkte, sodass das gelernte SVM dünnbesetzt ist. Merkmalsvektoren mit einem $\alpha = 0$ sind nicht Teil des SVM-Modell und müssen folglich auch nicht gespeichert werden. Der Grund liegt im diskriminativen Charakter der SVM, die ausschließlich die für die Trennfunktion notwendigen Aspekte modelliert. Die SV liegen folglich im Bereich der Diskriminante, der im Idealfall nur einen Bruchteil des durch Daten belegten Merkmalsraumes umfasst.

Der Anteil der Support Vektoren am Gesamtdatensatz ermöglicht Rückschlüsse auf die Modellqualität. Ihre Anzahl ist jedoch wenig aussagekräftig, da auch viele SV bei einer hohen Modellqualität auftreten können. Wie man diesen Ansatz unter Einbeziehung der relativen Lage der SV untereinander verfeinert und für eine approximative Modellbewertung nutzt, wird im nächsten Kapitel gezeigt.

Span-Estimate für eine effiziente Modellbewertung

Ein kritischer Faktor für die Performanz beim Lernen eines SVM-Modells ist die Bestimmung des Wertes für den SVM-Parameter C und ggf. der Werte weiterer Kernel-Parameter (vgl. Formel (2.5)). Der optimale Wert für C ist abhängig von den Eigenschaften des Problems, bzw. den Eigenschaften der Trainingsdaten in Bezug auf z.B. den Grad der überlappenden Klassen oder die Datenpunktdichte im Bereich der Trennfunktion. Infolgedessen wird dieser Parameter anhand von Trainingsdaten bestimmt. Hier ist dies besonders relevant, da bei der Merkmalsselektion für die einzelnen Trennfunktionen der ordinalen SVM wiederholt ein Modell gelernt und folglich ein optimales C bestimmt werden muss.

Da die Funktion der Modellqualität nicht-konvex ist, wird üblicherweise auf eine Grid-Optimierung zurückgegriffen. Dabei wird die Modellqualität in Abhängigkeit von C in regelmäßigen Abständen bestimmt. Der C -Wert mit der höchsten Modellqualität wird dann für die finale Modellerstellung verwendet. Die Bestimmung der Modellqualität erfolgt in der Regel mit einer Kreuzvalidierung, wobei der Datensatz wiederholt in Trainings- und Testdaten aufgeteilt wird. Jedes Mal wird auf den Trainingsdaten ein Modell gelernt und anhand der Testdaten bewertet. Die Bestimmung der Modellqualität geschieht dann durch Mittelbildung aller Bewertungen. Die Leave-one-out-Error (Loo-Error) stellt den Extremfall der Kreuzvalidierung dar, wobei jeder Datenpunkt einmal aus den Trainingsdaten entfernt und mit dem dann gelernten Modell klassifiziert wird. Der Loo-Error liefert eine annähernd optimale Möglichkeit zur Modellbewertung und stellt daher die Referenz dar. Die hohe Genauigkeit geht jedoch einher mit enorm aufwändigen Berechnungen. Bei n Datenpunkten müssen n Modelle auf jeweils $n - 1$ Trainingsdaten gelernt werden.

Eine vielversprechende Alternative stellen sogenannte Fehlerschranken („Error Bounds“) dar, die anhand von Modelleigenschaften den Loo-Error durch Berechnung einer oberen Grenze approximieren. Verschiedene „Bounds“ wurden entwickelt, wovon der SV-Count den einfachsten und auch ungenauesten darstellt. Der Span-Estimate ermöglicht durch eine tieferegehende geometrische Analyse des Modells im Vergleich dazu eine realistischere Abschätzung der Modellqualität (Chapelle und Vapnik, 2000). Im folgenden Abschnitt wird gezeigt, warum der SV-Count eine Abschätzung des Loo-Errors ermöglicht und wie der Span-Estimate zusätzlich das individuelle Risiko eines Support Vektors abschätzt.

Ausgehend von einem einmalig auf den gesamten n Daten gelernten Modell bestimmt der SV-Count die Modellqualität durch

$$T_{SVC} = \frac{|SV|}{n}, \quad (2.10)$$

was dem relativen Anteil der Menge der Support Vektoren (SV) entspricht. Er ist eine obere Grenze für den Loo-Error, da bei seiner Berechnung nur Support Vektoren falsch klassifiziert werden können. Datenpunkte, die keine SVs sind, ändern nicht das Modell, wenn sie aus den Trainingsdaten entfernt werden. Dieser Ansatz ist sehr pessimistisch, da hier alle SVs als Ursprung einer potenziellen Fehlklassifikation angesehen werden.

Ob ein SV aber zu einer Fehlklassifikation führen kann, wenn er aus den Trainingsdaten entfernt wird, hängt von seiner relativen Position zu den anderen SVs ab. Ist der Support-Vektor $p \in SV$ dicht eingebettet in eine große Anzahl SVs, hat er nur geringen Einfluss auf

das Modell und verursacht wahrscheinlich keine Fehlklassifikation. Ist er hingegen isoliert, fungiert er als Hebelpunkt für die Trennfunktion und eine Fehlklassifikation ist wahrscheinlicher. Unter der Annahme, dass sich die SVs bei der Berechnung des Loo-Errors nicht ändern würden, kann diese relative Lage durch die Distanz zum Raum Λ_p beschrieben werden, der durch eine Linearkombination der übrigen SVs mit $0 < \alpha < C$ aufgespannt wird.

$$\Lambda_p = \left\{ \sum_{i \neq p, 0 < \alpha_i < C} \lambda_i \mathbf{x}_i, \sum \lambda_i = 1 \right\} \quad (2.11)$$

$$S_p^2 = d^2(\mathbf{x}_p, \Lambda_p) = \min_{\mathbf{x} \in \Lambda_p} (\mathbf{x}_p - \mathbf{x})^2 \quad (2.12)$$

Der Span-Estimate berechnet sich dann mittels der Kardinalität der Menge der gefährdeten Support-Vektoren

$$T_{span} = \frac{|\{SV_p, \alpha_p^0 S_p^2 \geq y_p f^0(\mathbf{x}_p)\}|}{n}, \quad (2.13)$$

wobei f^0 die Prädiktionsfunktion repräsentiert, die auf den gesamten Daten gelernt wurde. Die hier zugrundeliegende Annahme, dass die SVs bei der Berechnung des Loo-Errors identisch bleiben würden, ist in den meisten Fällen nicht erfüllt. Da der Anteil der Support-Vektoren, die die Annahme verletzen, typischerweise sehr gering ist, wird das Ergebnis kaum beeinträchtigt und stellt immer noch eine gute Approximation des Loo-Errors dar.

Durch einen Vergleich von Formel (2.10) und (2.13) wird deutlich, dass der Span-Estimate den SV-Count um eine Bewertung der einzelnen SVs erweitert und damit den Loo-Error genauer approximiert.

Das Approximationsverfahren Span-Estimate macht ein wiederholtes Lernen des Modells wie bei der strengen Berechnung des Loo-Errors überflüssig. Dies führt in praktischen Anwendungen zu einem Geschwindigkeitsvorteil im Rahmen mehrerer Größenordnungen (Chapelle und Vapnik, 2000). Auch auf Hyperspektraldaten ermöglicht das Approximationsverfahren eine im Vergleich zur Kreuzvalidierung deutlich effizientere Bestimmung der SVM-Parameter. Bei der laufzeitkritischen Merkmalsselektion im Kontext des ordinalen Klassifikationsmodells stellt diese Form der approximativen Modellbewertung einen vielversprechenden Ansatz zur Beschleunigung des Lernschrittes dar.

2.2.5 Support Vector Data Description

Die bisher diskutierten Methoden des maschinellen Lernens beziehen sich auf die kompakte und effiziente Modellierung des Stressprozesses. Mit der Support Vector Data Description (SVDD, Tax und Duin, 2004) wird hier ein Verfahren vorgestellt, das die Verbesserung des Signal-zu-Rausch-Verhältnisses durch eine Integration geometrischer Merkmale in die Analyse ermöglicht. Darüber hinaus stellt sie einen möglichen Ausweg aus dem Mangel an Annotationen dar. Die SVDD ist ein Verfahren zur Ein-Klassen-Klassifikation, das methodisch eng mit der SVM verwandt ist. Eine besondere Relevanz besitzt diese Methode für

Anwendungen im Bereich der Detektion von Stresssymptomen. Es werden nur gelabelte Trainingsdaten einer Klasse (positiv) benötigt und das gelernte Prädiktionsmodell ist dann in der Lage Abweichungen von dieser Klasse (negativ) zu detektieren. Dies gilt insbesondere bei der Detektion von Krankheitssymptomen, bei der die Klasse „gesund“ sehr gut zu annotieren ist und die Klasse „krank“ entweder nur mit unverhältnismäßig großem Aufwand zu annotieren oder derart vielgestaltig ist, dass eine repräsentative Annotation nicht möglich ist. Konsequenz dieses Ansatzes ist, dass nicht zwischen verschiedenen Ursachen für Anomalien, wie Krankheiten, Insektenbefall oder abiotischer Stress unterschieden werden kann. Das Problem bei der Detektion von Anomalien in hyperspektralen Bildern ist, dass diese in der hohen, durch die Geometrie hervorgerufenen Varianz innerhalb der Blätter überdeckt werden.

Die SVDD als Verfahren zur Anomaliedetektion bestimmt die Verteilung einer Klasse, d.h. die Bereiche des Merkmalsraums, die durch positive Beispiele belegt sind. Dies geschieht, indem die Trennfunktion bestimmt wird, welche die Daten mit minimalem Abstand einschließt. Im linearen Fall trennt eine Hypersphäre mit minimalem Radius die Daten vom restlichen Merkmalsraum. Im folgenden Abschnitt wird die Adaption der linearen SVM zum Zwecke der Anomaliedetektion gezeigt und anhand der hergeleiteten Prädiktionsfunktion erläutert, wie die Integration der Geometrie das Signal-zu-Rausch-Verhältnis verbessert. Die Formalismen sind eng an der linearen SVM orientiert (vgl. Formel (2.5)), aber anstatt die Breite des Margins zu maximieren, wird hier der Radius r des Kreises mit Mittelpunkt \mathbf{a} , der die Daten enthält, minimiert.

$$\min_{r, \mathbf{a}} r^2 + C \sum_{i=1}^n \xi_i \quad (2.14)$$

unter den Bedingungen

$$\|\mathbf{x}_i - \mathbf{a}\|^2 \leq r^2 + \xi_i, \quad \xi_i \geq 0, \quad \forall i \quad (2.15)$$

Analog zur C -SVM lässt sich dieses Problem mittels Lagrange-Multiplikatoren in das duale Problem überführen.

$$\max_{\alpha} \sum_{i=1}^n \alpha_i (\mathbf{x}_i \cdot \mathbf{x}_i) - \sum_{i=1}^n \sum_{j=1}^n (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (2.16)$$

unter der Nebenbedingung

$$0 \geq \alpha_i \leq C, \quad \forall i \quad (2.17)$$

Da in dieser Darstellung die Daten ausschließlich in Form von Skalarprodukten in die Optimierung eingehen, ist der Einsatz von Kernelfunktionen zur Bestimmung der Affinität möglich, wie es auch bei der SVM weit verbreitet ist (Schölkopf und Smola, 2002). In diesem Fall wird der Raum der Daten von einer nicht-linearen Hypersphäre umschlossen.

Bei der Anwendung auf neue, ungesehene Daten wird dann die Lage des Merkmalsvektors relativ zur Hypersphäre im Merkmalsraum bestimmt. Die Entscheidungsfunktion für einen

neuen Datenpunkt \mathbf{x} lautet dann

$$(\mathbf{x} \cdot \mathbf{x}) - 2 \sum_{i=1}^n \alpha_i (\mathbf{x} \cdot \mathbf{x}_i) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j (\mathbf{x}_i \cdot \mathbf{x}_j) \leq r^2, \quad (2.18)$$

womit der Abstand von \mathbf{x} vom Zentrum \mathbf{a} der Hypersphäre mit dem Radius r verglichen wird. Liegt der Punkt innerhalb der Hypersphäre, wird \mathbf{x} als zu den Daten gehörig angesehen, andernfalls als Anomalie markiert.

Von großer Bedeutung für die Integration der Geometrie in die Analyse spektraler Merkmale, ist hier die ausschließliche Abhängigkeit der Prädiktion von Skalarprodukten mit SVs (Formel (2.18)). Gleiches gilt auch für Formel (2.9). Das Verfahren zur Verbesserung der Signalqualität basiert auf der Erweiterung des spektralen Merkmalsraums durch Hinzufügen weiterer, geometrischer Merkmale. Bei hinreichend hoher Gewichtung der geometrischen Merkmale, ist der zu bewertende Merkmalsvektor nur noch zu SVs mit ähnlichen geometrischen Merkmalen affin. Alle anderen SVs haben keinen oder nur geringen Einfluss auf die Prädiktion. Somit wird durch die Integration geometrischer Merkmale die Anomalie nur noch im Kontext der Daten mit vergleichbarer Geometrie definiert. Dort ist die durch Störgrößen hervorgerufene Variabilität in den spektralen Daten deutlich geringer. Auf diese Weise kann der Einfluss der variablen Geometrie innerhalb des gesamten Bildes auf die Prädiktion deutlich reduziert werden. Diese Form der Geometrie-Integration in der Datenanalyse hat somit das Potenzial das Signal-zu-Rausch-Verhältnis deutlich zu verbessern. Die Anwendung dieses Ansatzes im Bezug auf die Detektion von Krankheitssymptomen in Zuckerrüben wird in Kapitel 3.3 demonstriert.

3 Zusammenfassung der wichtigsten Ergebnisse

In diesem Kapitel werden die wichtigsten Ergebnisse der beigefügten Arbeiten vorgestellt und diskutiert. Anhand der konkreten Experimente, ihrer Auswertung und den gewonnenen Erkenntnissen wird der Fortschritt im Bereich der Datenanalyse demonstriert.

In Kapitel 3.1 wird ein Klassifikationsverfahren zur frühzeitigen Detektion des trockenstressinduzierten Seneszenzprozesses vorgestellt. In einem ordinalen Klassifikationsmodell wird die Kontinuität der Stressprozesse für eine erhöhte Performanz und eine interpretierbare Merkmalsselektion genutzt. Die Untersuchungen basierten auf Zeitreihen von einzelnen Gerstenpflanzen im Labor und Maispflanzen im Freiland. Dabei ist ein signifikanter Einfluss der Pflanzengeometrie auf die spektralen Beobachtungen aufgefallen. Zur Analyse dieses Aspektes wird in Kapitel 3.2 ein Kalibrierverfahren für hyperspektrale Kameras in der Pflanzenphänotypisierung zum Zwecke der Referenzierung spektraler und geometrischer Merkmale vorgestellt. Validiert wurde das Verfahren anhand eines Pushbroom-Kamerasystems bestehend aus zwei Hyperspektralkameras und einer Linear-Verschiebevorrichtung. In Kapitel 3.3 werden Verfahren zur Interpretation der auf diese Weise erzeugten hyperspektralen 3D-Pflanzenmodelle vorgestellt. Ihr kombinierter Merkmalsraum wird mit funktionalen Modellen und Methoden des maschinellen Lernens im Hinblick auf Krankheitssymptome analysiert. Die Untersuchungen basieren auf Beobachtungen einzelner Zuckerrübenpflanzen im Labor durch Hyperspektralkameras und 3D-Laserscanner.

3.1 Ordinale Klassifikation für die Detektion von Trockenstress

Die frühzeitige Detektion von Trockenstress ist hochrelevant, da diese frühen Stadien bereits Auswirkungen auf den Ertrag am Ende der Vegetationsperiode haben können. Eine durch Hyperspektralbilder beobachtbare Auswirkung von Trockenstress ist die frühzeitige Alterung, die Seneszenz der Blätter. Diese ist geprägt von einem kontinuierlichen Prozess von vital zu abgestorben, in dessen Verlauf Pigmente abgebaut und im Endstadium die Zellstruktur zerstört wird (Taiz und Zeiger, 2010). Dichotome Klassifikatoren würden nur zwischen den zwei Klassen „vital“ und „seneszent“ unterscheiden, was dem Prozesscharakter der Seneszenz nicht gerecht wird. Eine informative Beschreibung des jeweiligen Vitalitätszustandes der Pflanzen als Ergebnis einer vollautomatischen Interpretation der Hyperspektralbilder geht darüber hinaus (Abb. 3.1).

Daher wurde hier ein Klassifikationsverfahren an die Eigenschaften des Trockenstressprozesses angepasst, welches seine Entwicklung präzise abbildet und eine hohe Performanz

ermöglicht. Das Verfahren wurde anhand von zwei Datensätzen mit Gerstenpflanzen und einem Datensatz eines Maisbestandes im Feld validiert. Veröffentlicht wurde dieses Verfahren von Behmann et al. (2014c) im *ISPRS Journal of Photogrammetry and Remote Sensing*. Der Aspekt des hohen Durchsatzes des ordinalen Klassifikators wurde in Behmann et al. (2014b) untersucht.

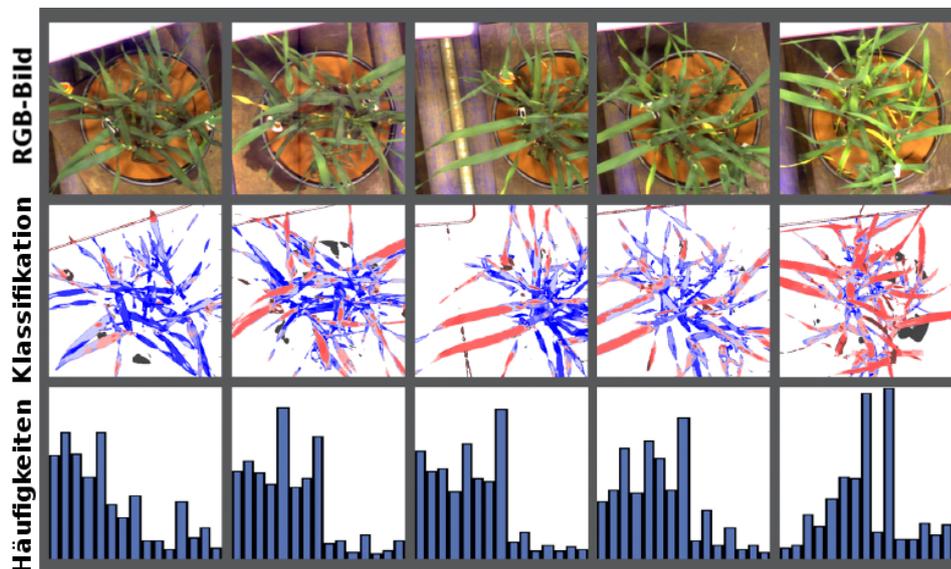


Abbildung 3.1: Charakterisierung des Vitalitätszustandes der Pflanzen anhand der Klassenverteilung (Behmann et al., 2014c). Dargestellt ist die RGB-Visualisierung, das Klassenbild (blau=vital und rot=seneszent) und die relativen Klassenhäufigkeiten im Histogramm für jeden zweiten Tag des Experiments.

Der eingeführte ordinale Klassifikator (Kapitel 2.2.2) auf Basis linearer Support Vektor Maschinen (Kapitel 2.2.4) differenziert die verschiedenen Stufen des Seneszenzprozesses (Abb. 3.1). Die Entwicklung erfolgte in Hinblick auf Echtzeitanwendungen und eine möglichst weitgehende Interpretierbarkeit der Ergebnisse. Um dies zu erreichen wurde der Analyseansatz an die spezifischen Dateneigenschaften der Hyperspektralbilder von Trockenstressexperimenten mit zeitlichem Verlauf angepasst. Indem der fortschreitende Stressprozess durch die unüberwachte Annotation auf ordinale Klassen abgebildet wird, kann die darauf aufbauende ordinale SVM genutzt werden, die im Vergleich zu generischen Verfahren einen höheren Durchsatz bei der Prädiktion erreicht. So benötigt sie deutlich weniger Trennfunktionen und nutzt darüber hinaus die schnellen linearen SVMs. Die Eigenschaft der Hyperspektralbilder, dass benachbarte Pixel in den meisten Fällen die Reflektanz von Blattregionen mit identischer oder ähnlicher Vitalität abbilden, wird zur Steigerung der Performanz und Interpretierbarkeit genutzt. Zu diesem Zweck wird die Kontinuität in der Bildebene als Kriterium sowohl zur Selektion repräsentativer Trainingsdaten, als auch informativer Merkmalsgruppen hinzugezogen.

Abb. 3.2 beschreibt die einzelnen Komponenten und ihr Zusammenspiel. In der Vorverarbeitung werden die hyperspektralen Signaturen der Pflanzenpixel im Vordergrund durch

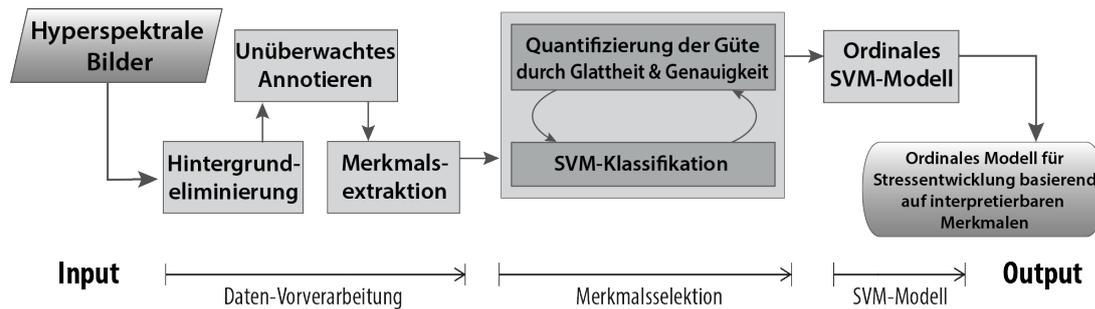


Abbildung 3.2: Ablaufdiagramm der Methode zur Detektion von Trockenstress (modifiziert aus Behmann et al., 2014c).

eine vollautomatische Methode mit ordinalen Labels versehen und die Gruppe der potentiellen Merkmale bestehend aus 20 Vegetationsindizes extrahiert. Als Merkmale werden hier Vegetationsindizes verwendet, da diese bereits mehr Informationen als einzelne Wellenlängen enthalten und darüber hinaus in der Literatur eine gewisse Semantik durch ihre Verknüpfung mit physiologischen Parametern besitzen (Rumpf et al., 2009). In der Merkmalsselektion werden aus diesen 20 Merkmalen jeweils die besten für den einzelnen ordinalen Klassenübergang selektiert und im letzten Schritt für die Bestimmung des ordinalen Klassifikationsmodells mit 15 Klassen verwendet.

Steigerung der Prädiktionsgeschwindigkeit

In Behmann et al. (2014b) wurde gezeigt, dass die ordinale Klassifikation im Vergleich zum etablierten Mehrklassenansatz one-vs.-one die Anzahl benötigter Trennfunktionen um 85% reduziert, was im Falle der linearen Trennfunktion proportional zur Komplexität der Prädiktion ist. Die Validierung auf einem Testdatensatz zeigt, dass 96,6% der Daten dem Bereich auf der ordinalen Skala zugeordnet werden, der die Zielklasse zuzüglich einer Distanz von zwei Klassen umfasst. Diese hohe Genauigkeit ergibt sich, da bei einer Gesamtgenauigkeit von 67,9% die Abweichungen fast ausschließlich zwischen direkt benachbarten Klassen auftreten. Da diese ordinalen Klassen eine Diskretisierung eines natürlichen und kontinuierlichen Prozesses darstellen, haben ordinal benachbarte Klassen eine sehr ähnliche Bedeutung im Bezug auf die Vitalität der Pflanze. Auswirkungen auf die Detektion von Trockenstress durch die Anwendung dieses angepassten Modells konnten daher bei den untersuchten Datensätzen nicht festgestellt werden.

Dieses ordinale Klassifikationsmodell wird aus linearen Klassengrenzen zusammengesetzt, da die komplexeren nicht-linearen SVMs keine signifikante Steigerung der Genauigkeit mit sich brachten. Daher konnten lineare SVMs genutzt werden, die sowohl beim Lernen (Joachims, 2006), als auch bei der Klassifikation performanter als nicht-lineare SVMs sind. Beim Lernschritt müssen außerdem keine zusätzlichen Kernel-Parameter optimiert, sondern ausschließlich der SVM-Parameter C bestimmt werden. Eine weitere Steigerung der Performanz der Parameteroptimierung ermöglicht der Span-Estimate (Kapitel 2.2.4, Formel (2.13)) zur Bestimmung des SVM-Parameters ohne Kreuzvalidierung.

Die ordinale Struktur des verwendeten Prädiktionsmodells schafft darüber hinaus die Voraussetzung für die Anwendung spezifischer Merkmalskompositionen für die einzelnen Klassenübergänge. Mit Hilfe eines Wrapper-Ansatzes werden die optimalen Merkmalsgruppen

für die einzelnen Trennfunktionen bestimmt (Kapitel 2.2.3). Dies führte zu kompakteren Modellen, die folglich auch schneller angewendet werden können. Die etablierten generischen Modelle nutzen hingegen ein Merkmalsset für alle Trennfunktionen. Dies stellt folglich einen Kompromiss dar und erfordert potentiell mehr Merkmale um eine vergleichbare Prädiktionsgüte zu erreichen.

Neben der Kontinuität auf der ordinalen Skala wird in diesem Analyseverfahren auch die Kontinuität in der Bildebene genutzt. So dient sie der Bestimmung repräsentativerer Trainingsdaten, die kompaktere Modelle und folglich auch ein beschleunigtes Lernen und Klassifizieren ermöglicht. Zu diesem Zweck wird durch den SLIC-Superpixel-Algorithmus das Hyperspektralbild in homogene und kompakte Bereiche segmentiert (Achanta et al., 2010). Durch die Auswahl der homogensten Superpixel und Berechnung des mittleren Reflektanzspektrums wurde die Anzahl der benötigten Trainingsdaten um bis zu 50% gegenüber einer randomisierten Auswahl reduziert. Der Grund hierfür liegt sowohl in der Auswahl von stabilen Bereichen ohne Mischpixel, als auch in der Reduktion des Messrauschens durch Mittelbildung.

Die Annahme über die Kontinuität des Stressprozesses in der 2D-Bildebene wird weiterhin als zusätzlicher Aspekt bei der Merkmalsselektion berücksichtigt. Neben der Klassifikationsgüte wird auch die Glattheit des prädizierten Klassenbildes in die Optimierungsfunktion des Wrappers einbezogen. Räumlich hochvariable Merkmale werden auf diese Weise in ihrer Relevanz abgewertet, da ein sehr rauhes, durch viele Klassengrenzen geprägtes Bild schwer interpretierbar und darüber hinaus auch biologisch unplausibel wäre, da benachbarte Bereiche auf einem Blatt einen ähnlichen Vitalitätsstatus besitzen. Die Zielfunktion der Merkmalsselektion (Behmann et al., 2014c, Formel (2)) wird somit durch die geometrische Nachbarschaft der Pixel mitgeprägt und bezieht auf diese Weise die projizierte 3D-Geometrie der Pflanze mit in die Analyse ein.

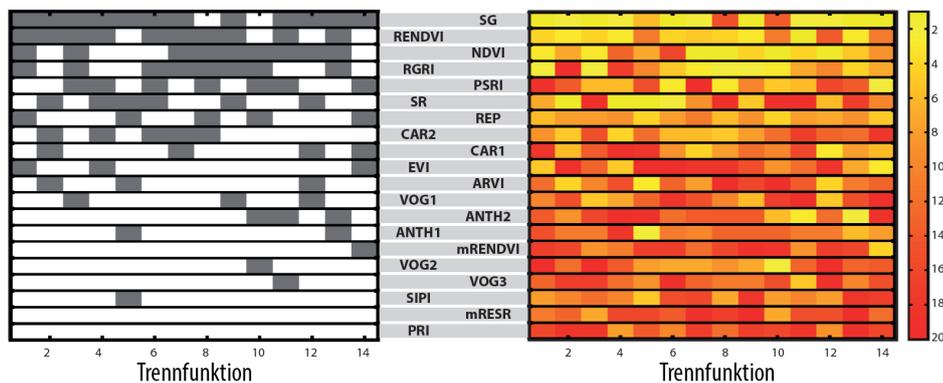


Abbildung 3.3: Selektierte Merkmale für die einzelnen Klassenübergänge der ordinalen Klassifikation (modifiziert aus Behmann et al., 2014c). Links sind die genutzten Vegetationsindizes mit schwarz markiert und rechts ihr Rang im Wrapper-Algorithmus dargestellt. Die vollständigen Namen und Formeln zu den Abkürzungen der Vegetationsindizes sind in Behmann et al. (2014c) enthalten.

Experimente

Validiert wurde die Methode anhand zweier Zeitreihen-Datensätze von Gerstenpflanzen unter Trockenstress aus den Jahren 2010 und 2011 und eines Datensatzes von Mais im Freiland unter vier verschiedenen Behandlungen. Die Behandlungen der einzelnen Pflanzen (0%, 50% und 100% Bewässerung) bzw. Feldbereiche waren bekannt. Für den Skalenübergang vom Pixel auf die Gesamtpflanze wurde die Verteilung der prädizierten ordinalen Klassen verwendet (Abb. 3.1). Die Vitalität der Gesamtpflanze wird somit durch die Klassenverteilung der Einzelpixel in Form eines Histogramms beschrieben. In Abb. 3.1 wird deutlich, dass sich die Klassenverteilung mit dem durch Trockenstress induzierten Seneszenzprozess verändert. Dies wird sowohl anhand des Falschfarbenbildes, als auch im Histogramm deutlich. Als Qualitätskriterium wurde der Zeitpunkt, an dem eine Separierung der verschiedenen Behandlungsgruppen möglich war, genutzt. Ein frühestmöglichster Zeitpunkt ist erstrebenswert um die Auswirkungen auf den Ertrag und den Ressourceneinsatz zu optimieren.

Ein Ergebnis der Datenanalyse stellt die Zusammensetzung der für die einzelnen Klassenübergänge spezifischen Merkmalssets dar. Die Merkmalsauswahl enthält Anhaltspunkte auf pflanzen-physiologische Prozesse, da VIs als Merkmale fungieren. Welche Merkmale als relevant für die einzelnen Stadien der Trockenstressreaktion selektiert werden, liefert somit Hinweise auf die für die Klassifikation relevanten Phänomene. In Abb. 3.3 wird die Abhängigkeit des gewählten Merkmalssets vom Stadium des Seneszenzprozesses gezeigt. Es wird deutlich, dass es sowohl sehr spezifische Merkmale gibt, als auch solche, die informativ für einen Großteil der Klassenübergänge sind. Über alle Trennfunktionen hinweg werden der SG und der NDVI als informativste Vegetationsindizes identifiziert. Im Gegensatz dazu tendiert das Verfahren eher zu einer Verwendung des SR bei vitalen Übergängen und des ANTH2 bei fortgeschrittenen Stresstadien. Letzterer wird verknüpft mit der Konzentration der Anthocyane, welche in den letzten Stadien der Seneszenz gebildet werden (Lee, 2002).

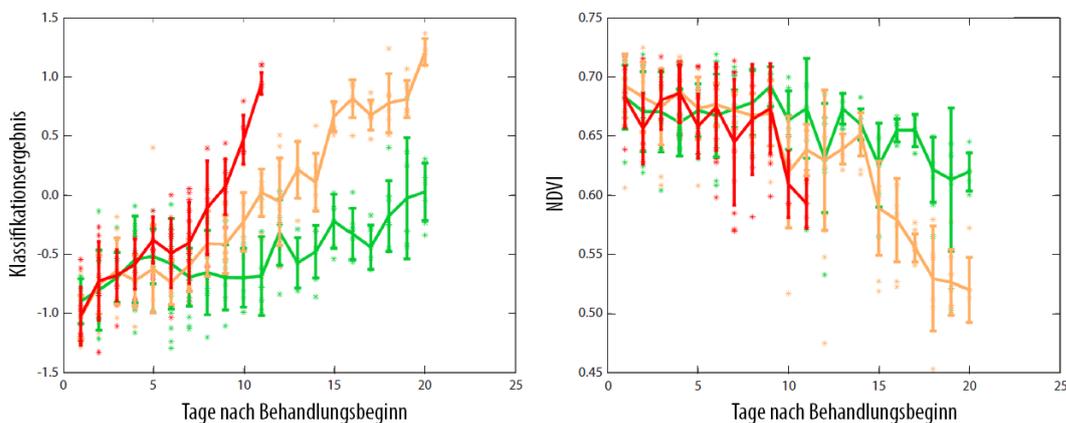


Abbildung 3.4: Trockenstressprädiktion bei Gerstenpflanzen mit drei Behandlungsgruppen (rot=unbewässert, gelb=teilmässert, grün=vollmässert). Anhand des klassifizierten mittleren Stresszustands inkl. Standardabweichung wird das vorgestellte Analyseverfahren mit dem NDVI verglichen (modifiziert aus Behmann et al., 2014c).

In Abb. 3.4 ist die mittlere Trajektorie der Vitalität der drei Behandlungsgruppen über den Zeitverlauf des Experiments von 2011 dargestellt. Der Vergleich mit dem bekanntesten Vegetationsindex NDVI, der auch für die Abschätzung der Pflanzenvitalität eingesetzt wird, macht deutlich, dass eine Trennung der Behandlungsgruppen vollbewässert/unbewässert drei Tage und die Trennung der Behandlungsgruppen vollbewässert/teilbewässert sechs Tage früher gelingt. Die unbewässerten Pflanzen wurden nach Tag 11 aus dem Experiment entfernt, da sie selbst für das bloße Auge deutlich sichtbare Trockenstresssymptome aufwiesen. Die Auswertung des Experiments von 2010 erzielte vergleichbare Ergebnisse, jedoch bei einer deutlich reduzierten zeitlichen Auflösung.

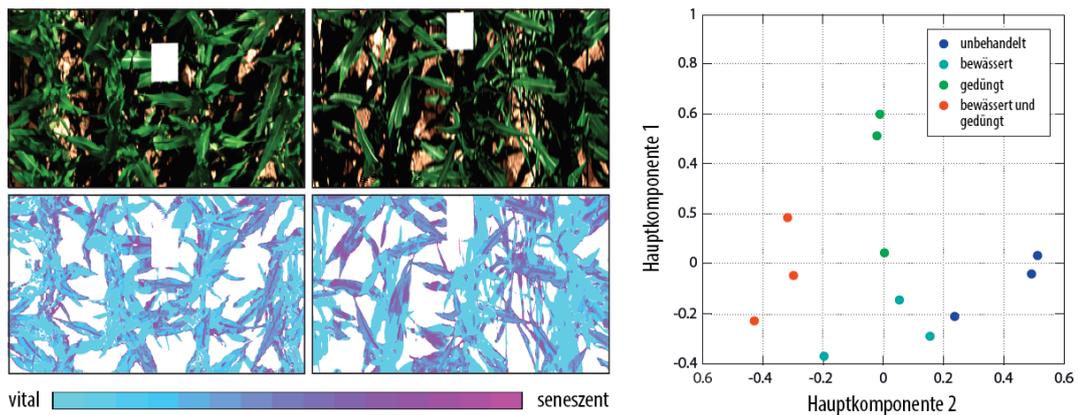


Abbildung 3.5: Klassifikation der Vitalität bei Maispflanzen unter vier unterschiedlichen Behandlungen. Links sind RGB-Visualisierungen und Klassenbild dargestellt und rechts die beiden ersten Hauptkomponenten der Klassenverteilung (modifiziert aus Behmann et al., 2014c).

Das Verfahren wurde zusätzlich auf einem Datensatz von Maispflanzen im Freiland evaluiert, wobei die Merkmale von der Gerste übernommen wurden. Dieser Datensatz zeichnet sich dadurch aus, dass anstatt Zeitreihen vier verschiedene Behandlungsformen (bewässert-gedüngt, unbewässert-gedüngt, bewässert-ungedüngt, unbewässert-ungedüngt) mit je drei Wiederholungen im Freiland gemessen wurden. Im linken Teil von Abb. 3.5 ist die pixelweise Interpretation der Spektren nach dem beschriebenen Verfahren visualisiert. Unterschiede, die im RGB-Bild verborgen sind, werden im Klassenbild sichtbar. Zur Visualisierung der gewonnenen Beschreibung der einzelnen Bilder wurde eine Hauptkomponentenanalyse der Klassenverteilungen durchgeführt. Hier wird deutlich, dass eine Separierung der vier Behandlungsformen mittels linearer Funktionen möglich ist. Somit konnte gezeigt werden, dass das Verfahren auch im Freiland subtile Unterschiede der Vitalität detektiert.

Ergebnisse

Das vorgestellte Verfahren der ordinalen Klassifikation in Kombination mit einer spezifischen Merkmalselektion ist besonders für die Interpretation hyperspektraler Bilder geeignet, da die hohe Prädiktionsgeschwindigkeit mit einer weitgehenden Interpretierbarkeit gekoppelt ist. Diese Auslegung auf den Echtzeiteinsatz ist hochrelevant für mobile land- oder luftgestützte Sensorplattformen im Feld. Durch den anhaltenden technischen Fortschritt und

der steigenden spektralen und räumlichen Auflösung wird das Speichern der Rohdaten und der Transport zu den stationären Auswertesystemen immer unwirtschaftlicher. Gleiches gilt auch für Hochdurchsatzanlagen, die immer häufiger auch mit hyperspektralen Kameras ausgestattet werden. Auch hier kann die Wirtschaftlichkeit gesteigert werden, indem im laufenden Betrieb nur die Analyseergebnisse gespeichert werden.

Die sehr gute Klassifikationsgüte des Gesamtverfahrens basiert zum Teil auf der Einbeziehung der Geometrie, hier in Form von 2D-Nachbarschaften im Bild. Bei der Betrachtung der Hyperspektralbilder und der Klassifikation ist deutlich geworden, dass die lokale 3D-Geometrie, z.B. in Form der Blattneigung, einen Teil des gemessenen Signals erklärt. Zur Untersuchung dieser Effekte wurde die Geometrie zusätzlich erfasst und zur Referenzierung mit den Hyperspektralbildern ein Verfahren entwickelt, welches im nächsten Abschnitt vorgestellt wird.

3.2 Sensorfusion für hyperspektrale 3D-Pflanzenmodelle

Die Fusion von 3D-Modellen und hyperspektralen Bildern zu hyperspektralen 3D-Pflanzenmodellen adressiert zwei Aspekte, die die Analyse von Pflanzeigenschaften mit hyperspektralen Kameras behindern. Die verbreiteten Hyperspektralkameras besitzen einen begrenzten spektralen Messbereich, da die Sensorkomplexität mit wachsendem Messbereich aufgrund physikalischer Begrenzungen enorm anwächst. Sie sind folglich jeweils nur für einen Teil des relevanten Spektrums sensitiv z.B. im sichtbaren Bereich und nahem Infrarot (VISNIR) oder dem kurzwelligen Infrarot (SWIR). Dies begrenzt die Anzahl der Phänomene, die mit einer Messung beobachtet werden. Darüber hinaus beeinflusst die Pflanzengeometrie das beobachtete Signal in signifikantem Ausmaß. Dies ist seit langem bekannt (Brakke et al., 1989; Bousquet et al., 2005; Kassalainen et al., 2016), jedoch kann dieser Effekt ohne Zusatzinformationen über die Geometrie im Hyperspektralbild nicht zugeordnet und quantifiziert werden. Aufgrund fehlender 3D-Modelle werden in den meisten Fällen Faktoren, wie unterschiedliche Entfernungen und verschiedene Beobachtungs- und Beleuchtungswinkel, nicht separat erfasst. Somit verbleibt diese Störgröße in den Daten und beeinflusst das Ergebnis der Datenanalyse. Stattdessen wird häufig der Ansatz verfolgt, dass sich die verschiedenen geometrischen Effekte im Mittel aufheben und folglich mittlere Spektren eines größeren Bildausschnitts nicht betroffen sind. Dies mag in manchen Anwendungen der Fernerkundung erfolgversprechend sein, im Nahbereich ist es jedoch nicht zielführend. Hier würde jegliche räumliche Struktur und somit die Vorteile der Hyperspektralkamera gegenüber nicht-bildgebenden Sensoren verloren gehen.

Hyperspektrale 3D-Pflanzenmodelle kombinieren hyperspektrale Bilder mit einem 3D-Modell der Pflanze zu einem neuen Datentyp (Abb. 3.6). Die Auflösung der hyperspektralen 3D-Modelle ist dabei eng mit der Auflösung der Sensoren gekoppelt. Die hohe räumliche Auflösung der hyperspektralen Kameras erfordert hinreichend fein aufgelöste 3D-Modelle und eine entsprechend genaue Referenzierung (Kapitel 2.1.3). Die durch den 3D-Laserscanner aus Kapitel 2.1.2 gemessenen Punktwolken, die in triangulierter Form als 3D-Pflanzenmodelle fungieren, erfüllen diese Anforderungen. Aufgabe der Referenzierung ist die bidirektionale Transformation zwischen 3D-Oberflächenpunkt und 2D-Pixel zum Zwecke der gegenseitigen

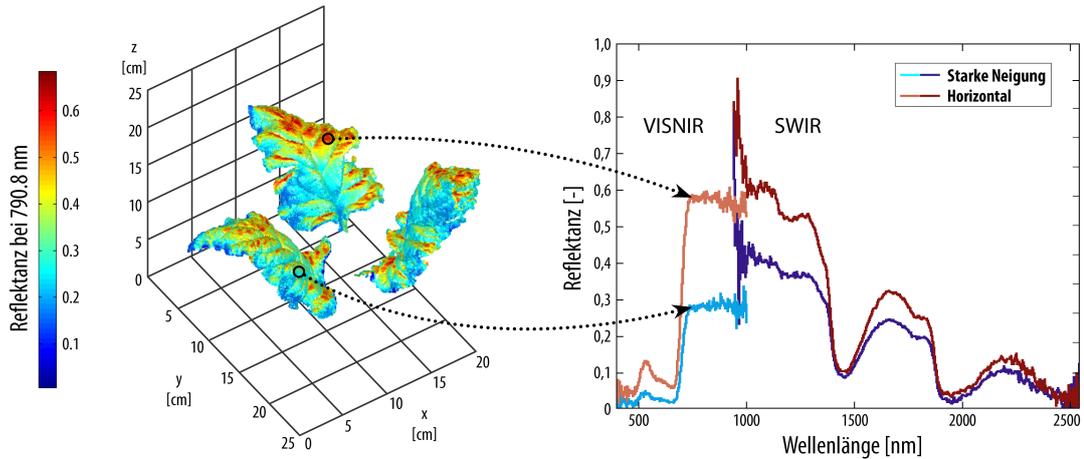


Abbildung 3.6: Hyperspektrales 3D-Pflanzenmodell einer Zuckerrübe mit den zwei hyperspektralen Texturen der VISNIR- und SWIR-Kamera (modifiziert aus Behmann et al., 2015b).

Zuordnung von Ort und spektraler Signatur. Die Zuordnung von Geometrie und hyperspektralem Signal und auch die räumliche Referenzierung zweier Hyperspektralkameras verlieren deutlich an Aussagekraft, wenn die Referenzierungsgenauigkeit die Pixelgröße übersteigt. In diesem Fall wäre keine sichere Zuordnung von Geometriemerkmalen und Pixeln bzw. von zwei Pixeln unterschiedlicher Kameras möglich. Daher werden hier nur Referenzierungen mit Subpixelgenauigkeit als geeignet angesehen.

Eine Referenzierung mit etablierten Verfahren der Kamerakalibrierung basiert in der Regel auf perspektivischen Kameras. Diese sind hier jedoch nicht anwendbar, da die genutzten Hyperspektralkameras nicht-perspektivische Pushbroom-Kameras sind. Zur Bestimmung der Transformation vom Koordinatensystem des 3D-Laserscanners zur 2D-Bildebene der Hyperspektralkamera ist folglich eine an die Eigenschaften der Pushbroom-Kameras angepasste Kalibrierung erforderlich.

Kalibrierung hyperspektraler Pushbroom-Kameras mittels eines Referenzobjekts

Die von Behmann et al. (2015b) im *ISPRS Journal of Photogrammetry and Remote Sensing* publizierte adaptierte Kamerakalibrierung für hyperspektrale Pushbroom-Kameras im Nahbereich ermöglicht diese Referenzierung. Die Anpassung an den Nahbereich wurde durch den Entwurf eines geeigneten Referenzobjekts und durch die über das lineare Modell von Gupta und Hartley (1997) hinausgehende Modellierung der nicht-linearen Phänomene erreicht. Anhand von zwei unterschiedlichen hyperspektralen Kameras, einer VISNIR und einer SWIR Kamera, wurde dieses Verfahren validiert.

Das Referenzobjekt, dargestellt in Abb. 3.7, definiert ein stabiles Koordinatensystem, das als Zwischenschritt bei der Transformation vom Koordinatensystem des Laserscanners in das Koordinatensystem der Kamera dient. Es wurde mit der Zielsetzung entworfen, eine effiziente und genaue Transformationsbestimmung zu den beiden Sensorsystemen zu ermöglichen.

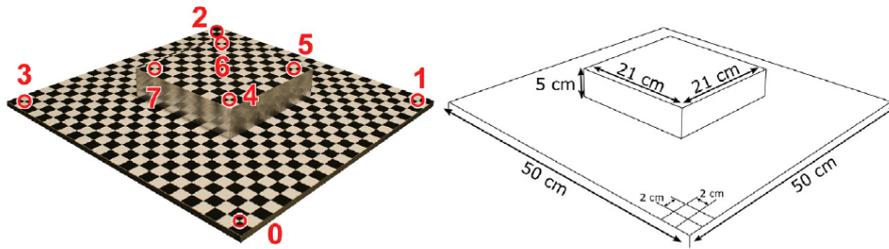


Abbildung 3.7: Referenzobjekt für die geometrische Kamerakalibrierung (Behmann et al., 2015b). Die durchnummerierten Eckpunkte markieren die Bildpunkte, die dem Punktdetektor zur Bestimmung aller Bildpunkte übergeben werden müssen.

Die Transformation vom System des Referenzobjekts in das System des Laserscanners erfolgte in der ersten Variante über identische Ebenen, die hochgenau mit dem Laserscanner gemessen werden konnten. Die zweite Variante ist dagegen mit koordinatenmäßig bekannten Kegelbohrungen versehen worden, die mit einem Messtaster mit einer Wiederholgenauigkeit von einigen Mikrometern angemessen werden können. Neben der gesteigerten Genauigkeit war die Hauptmotivation für diese Modifikation die nun entfallende Nachbearbeitung zur Bestimmung der Ebenenparameter.

Die Hauptaufgabe des Referenzobjekts ist die Bereitstellung von korrespondierenden Punkten für die Schätzung der Kameraparameter. Diese Punkte müssen sowohl im Bildkoordinatensystem, als auch im 3D-Raum bekannt sein. Im Gegensatz zu den verbreiteten Kameramodellen, dürfen hier aufgrund der spezifischen Eigenschaften der Pushbroom-Kamera diese Punkte nicht koplanar sein. Bei ausschließlich koplanaren Punkten würde das Normalgleichungssystem singulär werden, sodass das Referenzobjekt mit einer zentrischen Erhebung von 5cm entworfen wurde.

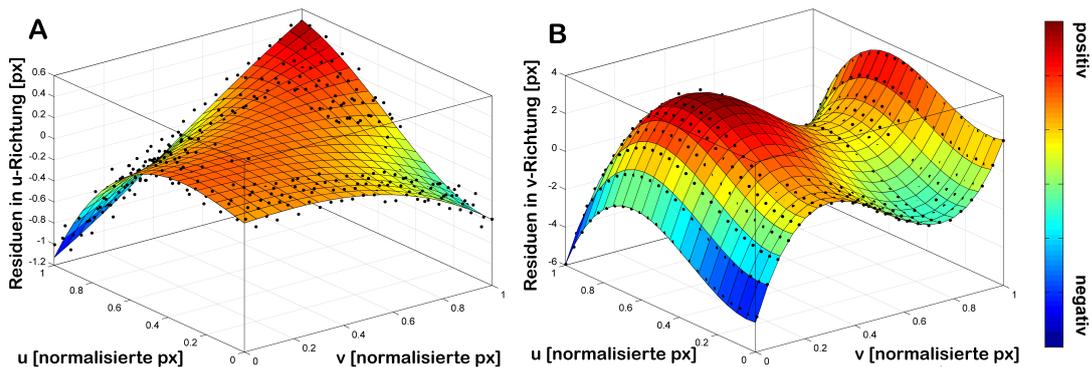


Abbildung 3.8: Ergebnis der phänomenologischen Modellierung der nicht-linearen Modellanteile durch 2D-Polynome (modifiziert aus Behmann et al., 2015b).

Die Eckpunkte einer Schachbrettextur liefern die korrespondierenden Punkte und bedecken das gesamte Objekt (Abb. 3.7). Die Bildkoordinaten dieser Punkte werden mit einem halb-automatischen Verfahren performant und mit einer Genauigkeit von 0.3px bestimmt. Die 3D-Koordinaten des Schachbrettmusters wurden vorher durch taktile Messungen hochgenau bestimmt. Einander zugeordnet bilden die 2D-Bildkoordinaten und die 3D-Punkte die Beobachtungen für die geometrische Kamerakalibrierung. Da die untersuchten Hyperspektralkameras Pushbroom-Kameras sind, wurde in einem ersten Schritt die lineare Pushbroom-Kamerakalibrierung aus Kapitel 2.1.3 verwendet.

Nicht-lineare Modellerweiterung für den Nahbereich

Die Anwendung des linearen „Pushbroom“-Kameramodells (Kapitel 2.1.3, Formel (2.3)) führte jedoch zu Residuen bei der Rückprojektion in der Größenordnung von bis zu 10px. Diese Abweichungen übersteigen die benötigte Subpixelgenauigkeit um ein Vielfaches. Die Gründe liegen in nicht-linearen Abweichungen der Nahbereichskamera vom linearen Kameramodell. Beispielhafte Faktoren sind neben der nicht-linearen Verzerrung auch Rotationen der Blickrichtung der Kamera während des Verschiebevorgangs und Variationen in der Verschiebegeschwindigkeit. Das daraus resultierende Gesamtphänomen ist jedoch räumlich glatt und ohne Brüche ausgeprägt. Mittels 2D-Tschebyschow-Polynomen dritten Grades werden die Residuen approximiert und somit das nicht-lineare Gesamtphänomen modelliert (Abb. 3.8). Als Grundlage für die Schätzung der Polynomkoeffizienten dienen die Messpunkte des Referenzobjekts, welche zu diesem Zweck hinreichend dicht und homogen verteilt über annähernd den gesamten Sichtbereich der Kamera positioniert wurden.

Tabelle 3.1: Ausgewählte Modellparameter der VISNIR- und der SWIR-Kamera. Der Mittelwert μ und die Standardabweichung σ (Rep.) wurden für jeden Sensor aus 15 unabhängigen Kalibrierungsprozeduren hergeleitet. Die Prozeduren umfassten die Bildaufnahme, Punktextraktion und Modellschätzung. Die Standardabweichung (Prop.) wurde mittels Varianzfortpflanzung mit den Normalgleichungen bestimmt (unter Annahme von unkorrelierten Koordinatenmessungen mit einer Genauigkeit von 0.3px).

Kamera		Brennweite f [px]	Hauptpunkt p_v [px]	Schrittweite $ \mathbf{v} $ [mm]
VISNIR	μ	2572.6	678.7	0.33
	σ (Rep.)	5.32	1.12	0.0002
	σ (Prop.)	8.56	1.06	0.000007
SWIR	μ	969.7	176.9	1.12
	σ (Rep.)	0.98	0.26	0.006
	σ (Prop.)	10.13	1.98	0.00009

Mit der Kombination aus linearem Pushbroom-Kameramodell und nicht-linearem Polynomansatz wurde das Kameramodell mit einer Genauigkeit bestimmt, die einen Rückprojektionsfehler von deutlich unterhalb des Pixelabstands ermöglicht. Im Mittel lagen die Residuen auf dem Referenzobjekt im Bereich von 0.1mm mit einer maximalen Größe von 0.2mm bei

der VISNIR-Kamera. Die Kameraparameter waren in Wiederholungsmessungen stabil und ihre Genauigkeiten im Rahmen der Varianzfortpflanzung bestimmbar (siehe Tab. 3.1).

Im Zuge der geometrischen Kamerakalibrierung wurde auch der wellenlängenabhängige Anteil der Abbildungseigenschaften untersucht. Da mit der Hyperspektralkamera die Intensitäten von Licht unterschiedlichster Wellenlänge an verschiedenen Positionen auf dem Sensor beobachtet werden, wurde überprüft, ob die unterschiedlichen Wege des Lichts durch die Optik zu geometrischen Effekten im Bild führt. Überprüft wurde dies, indem die einzelnen Bänder des Hyperspektralbildes als unabhängige panchromatische Bilder interpretiert wurden. Die Bildkoordinate eines Objektpunktes in den Bildern sollte, falls kein wellenlängenabhängiger geometrischer Effekt vorliegt, immer identisch sein (Abb. 3.9). Die SWIR-Kamera zeigt keinen klaren Trend und der Effekt ist zu vernachlässigen. Die VISNIR-Kamera hingegen zeigt eine kontinuierliche Entwicklung über das beobachtete Spektrum, die insbesondere im Bereich von 400nm bis 600nm Werte von bis zu ± 0.2 px aufweist. Damit bewegt sich dieser Effekt am oberen tolerierbaren Grenzwert, und eine Integration in das Kameramodell ist hier nicht erforderlich. Bei Kameras mit abweichenden Optiken oder Bauformen kann dieser Effekt aber durchaus relevant sein.

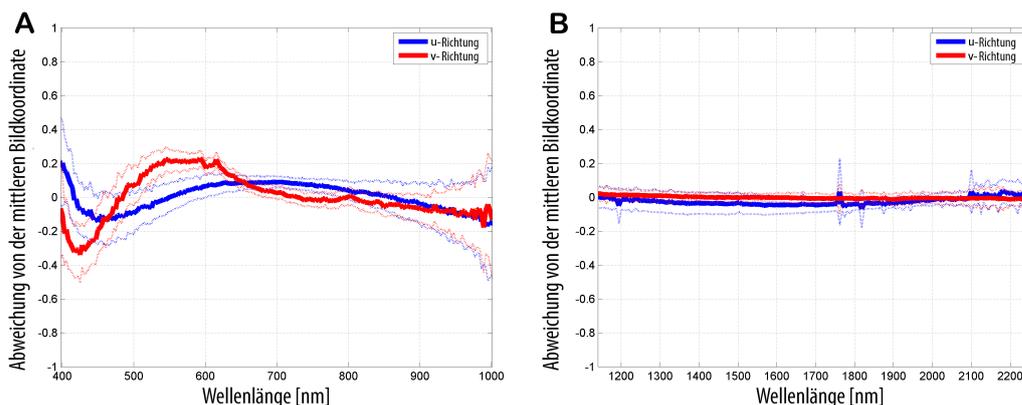


Abbildung 3.9: Wellenlängenabhängige Verzeichnung der (A) VISNIR- und (B) SWIR-Hyperspektralkamera (modifiziert aus Behmann et al., 2015b).

Ergebnisse

Die Datenfusion der spektralen und geometrischen 3D-Merkmale wird nach erfolgreicher geometrischer Kalibrierung mit zwei verschiedenen Zielsetzungen durchgeführt. Einerseits erfolgt die Fusion im Bildraum, wobei 3D-Merkmale wie Distanz oder Neigung den einzelnen Spektren zugeordnet werden. Dabei wird eine weitere Bildebene mit der Auflösung des Hyperspektralbildes angelegt. Im Falle der Distanz entspricht dies einem Tiefenbild. Alternativ wird die Datenfusion im 3D-Raum durchgeführt. Dabei wird jedem Oberflächenpunkt der Pflanze ein oder mehrere Spektren zugeordnet. Das entstehende hyperspektrale 3D-Pflanzenmodell kann einen oder auch mehrere hyperspektrale Texturlayer besitzen, wie in Abb. 3.6 dargestellt. Erst das zusätzliche 3D-Modell ermöglicht hier eine pixelgenaue Referenzierung der beiden Kameras, wodurch der gesamte Spektralbereich von 400nm bis 2500nm abgedeckt wird. Ohne 3D-Pflanzenmodell und die eingeführte Kamerakalibrierung

wäre die gezeigte pixelgenaue Zuordnung der spektralen Informationen zweier Kameras nicht möglich.

Das vorgestellte Verfahren zur Kalibrierung hyperspektraler Kameras für die Pflanzenphänotypisierung im Nahbereich erfüllt die qualitativen Anforderungen der Subpixelgenauigkeit durch die nicht-lineare Modellerweiterung. Durch den Einsatz des zu diesem Zweck entworfenen Referenzobjekts unterstützt es eine unkomplizierte und zeiteffiziente Anwendung. Dies ist insbesondere in einem Forschungsbetrieb mit regelmäßig wechselnden Experimenten und Sensorkonfigurationen von größter Bedeutung. Im Produktiveinsatz ist ein statisches Kalibrieremuster zu bevorzugen, welches im Rahmen einer Online-Kalibrierung regelmäßig beobachtet wird. Basierend auf der Kamerakalibrierung können nun 3D-Geometrien und Hyperspektraldaten mit der geforderten Genauigkeit zu hyperspektralen 3D-Pflanzenmodellen fusioniert werden. Im nächsten Kapitel wird gezeigt, wie der somit erweiterte Merkmalsraum im Hinblick auf geometrische Effekte nutzbar gemacht werden kann.

3.3 Geometrische 3D-Merkmale zur Reduktion von Störgrößen

Die gezeigte Kalibrierung der hyperspektralen Pushbroom-Kameras legt die Grundlage für die Referenzierung geometrischer und spektraler Informationen und die Erstellung von hyperspektralen 3D-Pflanzenmodellen. Diese Modelle erweitern den spektralen Merkmalsraum um geometrische 3D-Merkmale auf Ebene der Einzelpixel. Neben dem Reflektanzspektrum liegen nun ergänzende Geometrieinformationen zu der dem Pixel zugeordneten Blattoberfläche und ihrer Nachbarschaft vor. Diese Datengrundlage ermöglicht die Untersuchung von spektralen Phänomenen, die auf geometrische Faktoren zurückgeführt werden können. Ziel ist hier die geometrischen Merkmale zu nutzen, um die Effekte aus den hyperspektralen Bildern zu entfernen oder bei der Datenanalyse zu berücksichtigen. Aufgrund der innovativen Datengrundlage ist weitestgehend unbekannt, welche Modelle und Methoden den erweiterten Merkmalsraum zur Verbesserung der hyperspektralen Signalqualität optimal auswerten. Hier wird ein funktionales Modell, die Integration in Methoden des maschinellen Lernens und ein geometrischer Zusammenhang genutzt (Behmann et al., 2015a; Roscher et al., 2016a).

Welcher Ansatz verfolgt wird, ist abhängig von der Mess- und Modellierbarkeit des einzelnen Faktors. Bei bekannten funktionalen Zusammenhängen und guter Messbarkeit wird der Einfluss der Geometrie auf die spektralen Merkmale explizit berechnet. In einem zweiten Schritt kann dieser Effekt dann aus den hyperspektralen Daten entfernt werden. Falls kein funktionales Modell bekannt ist, ermöglichen Methoden des maschinellen Lernens eine implizite Berücksichtigung des geometrischen Faktors im Rahmen eines Prädiktionsmodells. Eine Korrektur der hyperspektralen Daten ist bei diesem Ansatz jedoch nicht möglich. In Behmann et al. (2015a) und Roscher et al. (2016a) werden die geometrischen 3D-Merkmale „Distanz“ und „Neigung“ hinsichtlich ihrer Auswirkungen auf die beobachteten hyperspektralen Signale untersucht.

Distanzabhängige Beleuchtungsstärke

Das 3D-Merkmal „Distanz“ repräsentiert die Distanz zu den Beleuchtungskörpern während der Messung. Abgeleitet wird dieses Merkmal aus der Höhendifferenz des jeweiligen Punktes

auf der Pflanzenoberfläche zur 3D-Trajektorie der Kamera (vgl. Abb. 2.1). Dieses Merkmal ist mit Effekten in den hyperspektralen Daten gekoppelt, da die Beleuchtungsstärke mit wachsender Entfernung abnimmt. Bei der etablierten radiometrischen Normierung wird diese jedoch nur in der Distanz des Reflektanznormals bestimmt (siehe Kapitel 2.1.1). Aufgrund der physikalisch bedingten quadratischen Abnahme hat dieser Effekt im Nahbereich eine große Bedeutung. Die Größenordnung des Effektes ist dabei abhängig von den Höhendifferenzen innerhalb der Pflanze und der gewählten Höhe des Reflektanznormals. Dieser Effekt wurde direkt gemessen, indem die Abnahme der Beleuchtungsstärke in Abhängigkeit von Ort und Wellenlänge durch Beobachtung des Reflektanznormals in verschiedenen Distanzen bestimmt wurde. Diese Messungen erlauben nun pixelweise die lokal wirkende Beleuchtungsstärke zu bestimmen. Diese wurde dann als Korrektur in die radiometrische Normierung eingebracht (vgl. Abb. 3.10).

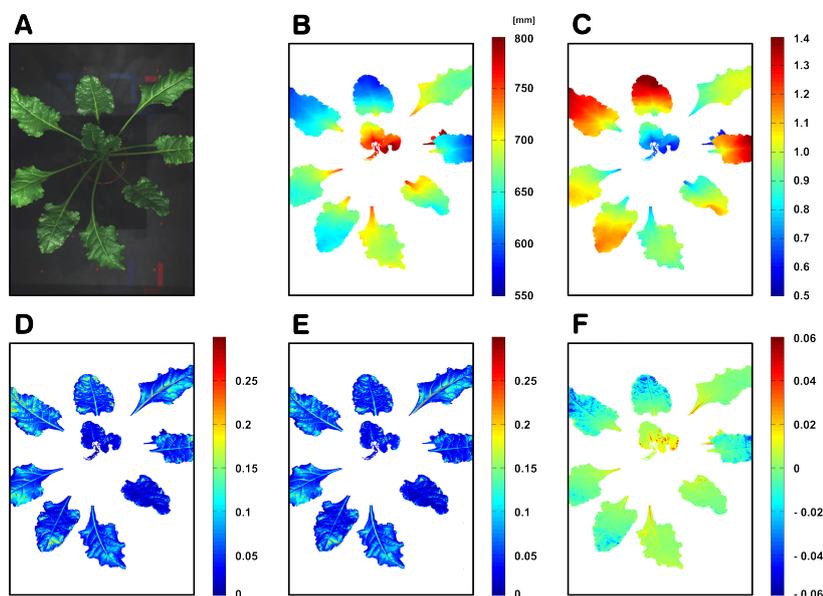


Abbildung 3.10: Effekte der distanzabhängigen Normierung hyperspektraler Daten bei Zuckerrüben (A) (Behmann et al., 2015a). Aufgrund der mit der Distanz (B) abfallenden Beleuchtungsintensität ergeben sich Korrekturfaktoren (C). Angebracht an das Hyperspektralbild (D) ergibt sich ein korrigiertes Hyperspektralbild (E). Die Korrektur (F) kann dabei bis zu 20% des Wertebereichs der Pflanze betragen.

In den Untersuchungen von Behmann et al. (2015a), veröffentlicht im Journal *Machine Vision and Applications* wurden Zuckerrübenpflanzen mit einer vertikalen Ausdehnung von etwa 30cm untersucht. Bei einer mittleren Positionierung des Reflektanznormals wurden Korrekturen bestimmt, die bis zu 5% des Messbereichs und somit 20% des Wertebereichs innerhalb der Pflanzen betragen. Bei der Beobachtung von Pflanzen mit größerer Höhenausdehnung sind folglich größere Korrekturwerte zu erwarten. Im Freiland mit natürlicher Beleuchtung ist dieser Effekt zu vernachlässigen, da der quadratische Abfall der Intensität aufgrund des großen Abstands zur Sonne keinen Einfluss hat.

Anomaliedetektion unter Berücksichtigung der Neigung

Das 3D-Merkmal „Neigung“ beschreibt den Winkel zwischen der lokalen Blattoberfläche und der Beobachtungsrichtung. Beide Kameras und auch die Beleuchtung sind zum Nadir ausgerichtet, sodass Beobachtungs- und Beleuchtungsrichtung genähert übereinstimmen. Bestimmt wird die Neigung pixelweise durch Berechnung des Normalenvektors einer Ebene durch die direkten Nachbarpixel im Tiefenbild. Sie beeinflusst die spektralen Merkmale, da die Blattfläche nicht vollständig diffus reflektiert und folglich keinen Lambert-Strahler darstellt. Stattdessen ist die beobachtete Reflektanz stark winkelabhängig, was durch eine „bidirectional reflectance distribution function“ (BRDF, Comar et al., 2012) beschrieben werden kann. Diese BRDF ist abhängig vom Beleuchtungswinkel, Beobachtungswinkel und Wellenlänge und spezifisch für die Blätter der einzelnen Pflanzensorten. Aufgrund der Abhängigkeit von der Wellenlänge sind verschiedene Bereiche des Spektrums in unterschiedlichem Maße betroffen, sodass auch robuste VI beeinflusst werden (Kassalainen et al., 2016). In Behmann et al. (2015a) wurde anhand einzelner Zuckerrübenpflanzen basierend auf den referenzierten geometrischen und spektralen Merkmalen die Abhängigkeit der Reflektanz von der Neigung gezeigt. Aufgrund der räumlichen Variabilität der Reflektanzeigenschaften innerhalb der Pflanze war eine hinreichende Isolierung dieses Effekts jedoch nicht möglich. Ein explizites Modell zur Entfernung der Neigungseffekte aus den Daten war auf der begrenzten Datengrundlage nicht herleitbar. Die Integration der Neigung in Prädiktionsmodelle ermöglichte jedoch eine Reduzierung der Effekte in den Analyseergebnissen. Die Resultate der Einbeziehung des Merkmals „Neigung“ in eine spektrale Auswertung mit Methoden des Maschinellen Lernens werden in Roscher et al. (2016a) gezeigt.

Auf einen Datensatz bestehend aus hyperspektralen 3D-Modellen einer gesunden und zwei mit der Cercospora Blattfleckenkrankheit infizierten Zuckerrüben wurden zwei Analyseverfahren angewendet. Verglichen wurde die Support Vector Data Description (SVDD, Kapitel 2.2.5) mit einem „sparse representation“-Ansatz (SR), welcher Daten mittels Linearkombination von Wörterbucheinträgen approximiert. Da topographische Wörterbücher verwendet werden, können Nachbarschaften der Wörterbucheinträge zu einer Erhöhung der Aussagekraft der Dekomposition beitragen. Beide Ansätze nutzen die Neigungsinformation und wurden jeweils mit einer Variante ohne Berücksichtigung der Geometrie verglichen. Zur Evaluierung der Prädiktionen wurden manuelle Annotationen der Symptomzentren genutzt. Der Vergleich der Prädiktionsqualität erfolgt durch die „area under curve“ (AUC, vgl. Tab. 3.2) der „precision-recall“- und „receiver operating characteristic“(ROC)-Kurven.

Es wurde die SVDD als Verfahren zur Anomaliedetektion verwendet, um Abweichungen von gesundem Pflanzengewebe zu detektieren. Zur Integration des 3D-Merkmals „Neigung“ wurde „Feature-Stacking“ angewandt. Dabei wird das 3D-Merkmal den spektralen Merkmalen angehängt. Dieser Ansatz bewirkt, dass die spektralen Informationen durch die SVDD in ihrem räumlichen Kontext bewertet werden. So zeigen beispielsweise Pixel mit annähernd horizontalen Oberflächen Effekte der Spiegelreflektion, die im Kontext der Gesamtpflanze als Anomalie bewertet werden können. Durch Integration der Neigung wird ein Pixel nunmehr ausschließlich mit Pixeln von Oberflächen ähnlicher Neigung verglichen und die Spiegelreflektion in der Regel nicht mehr als Anomalie detektiert. Dieser Ansatz der Datenfusion führte hier zu einer deutlichen Steigerung des Kontrasts zwischen gesundem und

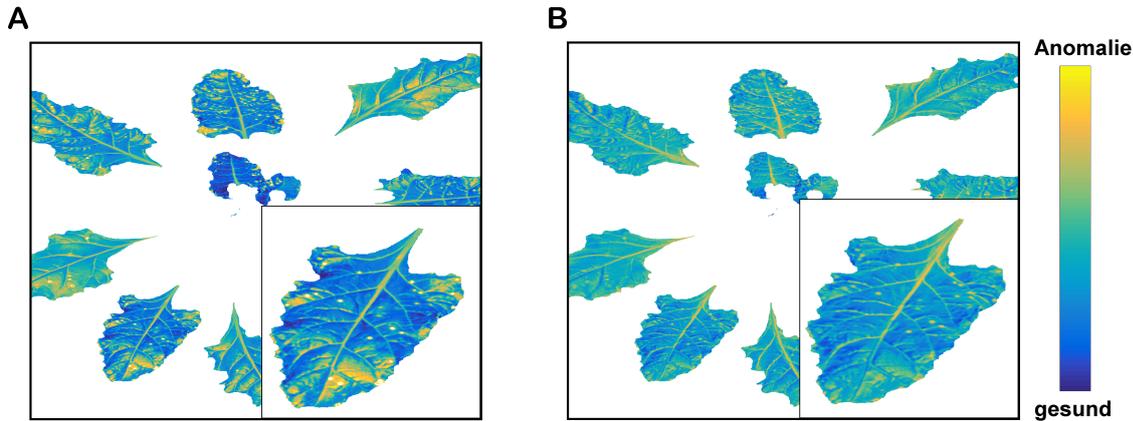


Abbildung 3.11: Entscheidungswert der SVDD, der die Abweichung der Reflektanzeigenschaften von denen einer vitalen Pflanze anzeigt (links ohne Geometrie und rechts unter Nutzung der Neigung). Im Vergleich zu (A) wird durch Berücksichtigung der Geometrie in (B) die Spiegelreflektion nicht mehr fälschlicherweise als Anomalie detektiert (modifiziert aus Roscher et al., 2016a).

symptombefahetem Blattgewebe bei einer gleichzeitigen Akzeptanz von Bereichen mit Spiegelreflektion (Abb. 3.11). Im Gegensatz zur SR müssen hier sowohl für die Trainingsdaten, als auch für die Testdaten zusätzliche Geometrieinformationen vorliegen.

Das alternative SR-Verfahren benötigt Geometrieinformationen hingegen nur für die einmalige Erstellung des topographischen Wörterbuchs. Anhand der vorliegenden Neigungsinformation zu jedem Wörterbucheintrag wird das Wörterbuch sortiert. Bei der Rekonstruktion können nun die Nachbarschaften so genutzt werden, dass Gruppen vergleichbarer Neigung gegenüber isolierten Wörterbucheinträgen bevorzugt werden. Die Ergebnisse werden durch die Gruppierung anhand der Neigung aussagekräftiger.

	SVDD		SR_Residuen		SR_Index*NumW	
	-in	+in	-TD	+TD	-TD	+TD
Pflanze 1	86.7	91.8	86.9	94.8	100.0	98.9
Pflanze 2	86.8	88.6	80.4	90.4	76.1	100.0

Tabelle 3.2: „Area under curve“ (AUC) Werte in [%] für die „receiver operator characteristics“ (ROC). Die Werte sind angegeben für die SVDD mit Neigungsinformation (+in) und ohne (-in) und für die „Sparse Representation“ (SR) mit topographischem Wörterbuch (+TD) und ohne (-TD). Für die SR sind die Auswertungen für die Residuen und für das Produkt des dominanten Wörterbuchelements mit der Summe der Gewichte gegeben.

Bei der Betrachtung der Ergebnisse zeigt sich der positive Effekt der zusätzlichen Neigungsinformation in annähernd allen Evaluationskriterien. Bei der SVDD zeigten sich im AUC-Wert Steigerungen von bis zu 5%. Im Gesamtergebnis erreichte der Wörterbuch-Ansatz höhere AUC-Werte, wobei in diesen Fällen ein dominantes Wörterbuchelement verwendet wurde. Das Auftreten eines derart dominanten Wörterbuchelementes und seine robuste Selektion sind jedoch erst auf einer breiteren Datenbasis zu prüfen. Zudem werden durch den SR-Ansatz nicht alle Symptome detektiert, was in die Berechnung der ROC-Kurve jedoch nicht einfließt.

Aufbauend auf Roscher et al. (2016a) werden die kombinierten Effekte von Neigung und Distanz in einem SR-Ansatz mit einem 2D-topographischen Wörterbuch in Roscher et al. (2016b) untersucht.

Korrespondierende Blattfläche der einzelnen Pixel

Ein weiterer Effekt der Kombination von Neigung und Distanz verfälscht nicht die spektrale Signatur, sondern erschwert die Interpretation von Prädiktionsergebnissen. Die bisher gezeigten pixelweisen Prädiktionen werden in der Regel anhand der Pixelanzahl zu einer Interpretation der Gesamtpflanze aggregiert (z.B wie in Kapitel 3.1). Dieses Gleichsetzen von Pixel und Anteil an der Pflanzenoberfläche kann die Ergebnisse jedoch massiv verfälschen, da die den einzelnen Pixeln zugeordnete Blattoberfläche stark in Abhängigkeit von Neigung und Höhe variiert. In Behmann et al. (2015a) wurde dieser Effekt anhand von Zuckerrübenpflanzen quantifiziert, die mit der Cercospora Blattfleckenkrankheit infiziert waren. Die 3D-Geometrie ermöglichte die Berechnung der betroffenen Blattfläche und einen Vergleich mit der betroffenen Pixelanzahl. In beiden Fällen wurde das identische Prädiktionsmodell verwendet. Dennoch konnten Differenzen von bis zu $\pm 15\%$ zwischen den beiden Ansätzen aufgedeckt werden, die ausschließlich auf die Blattgeometrie der untersuchten Pflanzen zurückzuführen sind (Tab. 3.3).

Tabelle 3.3: Differenz zwischen dem Anteil auffälliger Pixel und auffälliger Blattfläche bezogen auf den Anteil der betroffenen Pixel (Behmann et al., 2015a). Die Absolutwerte sind in Klammern angegeben.

	Betroffene Pixel	Betroffene Fläche [cm ²]	Differenz
Pflanze 1	3.13% (38377)	3.52% (55.28)	12.5%
Pflanze 2	0.41% (4632)	0.35% (4.14)	-14.6%
Pflanze 3	1.22% (12500)	1.41% (15.87)	13.5%

Ergebnisse

Die geometrischen 3D-Merkmale „Distanz“ und „Neigung“ ermöglichen im Zusammenspiel mit hyperspektralen Reflektanzmerkmalen neue Analyseansätze. Die Größenordnung der Korrekturen bzw. des positiven Effekts auf Analyseergebnisse wurde anhand von Experimenten mit Zuckerrübenpflanzen im Labor bestimmt. Das explizite, funktionale Modell für die „Distanz“ bestimmt Korrekturfaktoren, die bis zu 20% des Wertebereichs der untersuchten Zuckerrübenpflanze betragen. In ersten Versuchen zur impliziten Berücksichtigung der

„Neigung“ durch die SVDD konnte eine moderate Genauigkeitssteigerung von bis zu 5% erreicht werden. Die kombinierte Auswirkung von „Distanz“ und „Neigung“ auf die Größe der zugeordneten Pflanzenoberfläche deckte Abweichungen von bis zu 15% Neigung auf. Diese Größenordnungen sind zwar relevant für eine große Anzahl von Anwendungen, werden in der Praxis jedoch noch häufig als Teil des Messrauschens akzeptiert.

4 Schlussfolgerungen und Ausblick

In dieser Arbeit wurden neue Analyseverfahren und Modelle zur Interpretation von Hyperspektralbildern für die Stressdetektion entwickelt. Vergleichbare, etablierte Methoden sind bisher nur unzureichend in der Lage zwischen Veränderungen der Reflektanzsignatur durch Frühformen von Pflanzenstress und der natürlichen Variabilität zu unterscheiden. Ein Mangel an Labeln aufgrund der für das bloße Auge unsichtbaren Frühstadien, fehlende Geometrieinformationen zur Untersuchung der geometrischen Effekte im hyperspektralen Signal und unzureichende Methoden zur Integration der 3D-Merkmale in die Datenanalyse verhindern den Zugriff auf den physiologischen Stressprozess. Der Beitrag dieser Arbeit setzt sich zusammen aus Verfahren, die diese Defizite adressieren. Ein ordinales Klassifikationsmodell bestimmt den Stresszustand einzelner Pflanzen, wobei die aus einer Clusteranalyse gewonnenen nominalen Label in eine ordinale Struktur eingeführt werden. Zur Untersuchung der Geometrieeffekte wurde ein Verfahren zur gegenseitigen Referenzierung von Pflanzengeometrie und Hyperspektralbild entwickelt. Zur Integration der 3D-Merkmale Neigung und Distanz wurden drei spezifische Modelle entworfen und angewendet. Ein funktionales Modell erfasst die abnehmende Beleuchtungsintensität, ein Klassifikator integriert die Neigung und der geometrische Zusammenhang zwischen Pixelanzahl und Blattoberfläche verbessert die Interpretation von Prädiktionsergebnissen.

Bisher verhinderten fehlende Labelinformationen die Anwendung von Klassifikationsverfahren zur Detektion der Frühformen von Trockenstress. Mit der ordinalen Klassifikation wurde hier ein Verfahren zur Beschreibung des Vitalitätsstatus von Pflanzen eingeführt, welches Label vollautomatisch generiert und somit die Interpretation ungelabelter Datensätze ermöglicht. Die auf den ordinalen Labeln aufbauende ordinale SVM bestimmt als Klassifikationsmodell die Verteilung der Stressreaktion innerhalb der Pflanzen. Bei der Entwicklung dieses Analyseansatzes wurde die Methode gezielt auf eine Echtzeitfähigkeit und somit hohe Klassifikationsgeschwindigkeit hin entworfen. Im Vergleich mit generischen Ansätzen wurde durch das ordinale Klassifikationsmodell die Anzahl der Trennfunktionen um 85% reduziert. Die Anzahl der für eine Klassifikation mit n Klassen auszuwertender Trennfunktionen wurde nochmals durch eine binäre Baumstruktur auf $\log(n)$ reduziert. Durch Einbeziehung der 2D-Nachbarschaften auf den einzelnen Blättern in die Selektion repräsentativer Trainingsdaten konnte der Umfang der Trainingsdaten um bis zu 50% reduziert werden. Dies trägt zur Kompaktheit der Modelle und infolgedessen auch zur Steigerung der Prädiktionsgeschwindigkeit bei. Trotz des Fokus auf einen hohen Durchsatz, ist dieses Verfahren allen gängigen Vegetationsindizes weit überlegen. So konnte z.B. der Zeitpunkt der Stressdetektion im Vergleich zum NDVI um bis zu sechs Tage nach vorne verschoben werden. Die Anpassung an die Eigenschaften der Trockenstressreaktion durch die ordinale Modellstruktur und die räumlichen Glattheitsannahmen ermöglichte ein performantes Klassifikationsmodell, das Details der Zwischenstadien erhält und eine umfassende Beschreibung des Stresszustands einer Pflanze liefert.

Eine Einbeziehung der 3D-Struktur bei Pflanzen mit differenzierter Blattarchitektur in die Analyse scheiterte bisher häufig an einem Mangel an Sensoren und tauglichen Verfahren zur Verknüpfung der Sensordaten. Das Referenzierungsverfahren für 3D-Pflanzenmodelle und Hyperspektralbilder durch eine an den Nahbereich angepasste Kamerakalibrierung ermöglicht jetzt die gegenseitige Projektion mit Subpixelgenauigkeit. Daher eignet es sich für die Erstellung der Datengrundlage zur Untersuchung der Geometrieeffekte im hyperspektralen Signal. Darüber hinaus ermöglicht die entwickelte Referenzierung die pixelgenaue Kombination von Hyperspektralbildern unterschiedlicher Kamertypen für einen erweiterten Messbereich. Erreicht wurde dies durch ein für diesen Zweck entworfenes Referenzobjekt und die Einbeziehung der nicht-linearen Phänomene ins Kameramodell. Das Referenzobjekt unterstützt den praktikablen Messablauf, da es die Messpunkte für die Kamerakalibrierung bereitstellt und darüber hinaus auch die Verknüpfungspunkte zum Koordinatensystem des Laserscanners liefert. Das eingeführte Verfahren ermöglicht die Erstellung von hyperspektralen 3D-Pflanzenmodellen mit Subpixelgenauigkeit und liefert damit die Grundlage für die Untersuchung der geometrischen Effekte.

Wie dieser durch geometrische 3D-Merkmale erweiterte Merkmalsraum für eine verbesserte Interpretation von Hyperspektralbildern optimal genutzt werden kann, wurde bisher kaum untersucht. Mit den hier eingeführten effektspezifischen Modellen für die 3D-Merkmale Distanz und Neigung konnte der positive Effekt auf die Signal- bzw. die Prädiktionsqualität nachgewiesen werden. Da die Distanz einen bekannten Effekt auf die Beleuchtungsintensität besitzt, kam hier ein direktes Korrekturmodell zum Einsatz. Im untersuchten Datensatz betragen die Korrekturen bis zu 20% des Wertebereichs. Ohne Korrektur geht dieser Effekt in vollem Umfang in die Interpretation der spektralen Daten ein. Beim 3D-Merkmal Neigung war kein direktes Modell des Effekts in der benötigten Genauigkeit bestimmbar, sodass mit der SVDD ein Verfahren des maschinellen Lernens angewendet wurde. Eine Prädiktion von Cercospora-Krankheitssymptomen erfolgte hier im Kontext der lokalen Neigung, wodurch die Prädiktion um bis zu 5% verbessert wurde. Der kombinierte Effekt von Distanz und Neigung kann zu Abweichungen bei der Interpretation von pixelweisen Prädiktionen führen. Da hier den einzelnen Pixeln unterschiedlich große Blattflächen zugeordnet sind, entspricht der Anteil an auffälligen Pixeln nicht dem Anteil auffälliger Blattfläche. Die Berücksichtigung der Geometrie führte zu Verbesserungen von bis zu 15% im Vergleich zur geometriefreien Pixelanzahl.

Die Modelle und Methoden dieser Arbeit leisten in den adressierten Aspekten unsichtbare Frühstadien, geometrische Sensorkombination und Integration geometrischer Effekte einen Beitrag zur kontinuierlichen Weiterentwicklung der Interpretation hyperspektraler Bilder. Als Ausgangspunkt für weitere Untersuchungen, insbesondere bezüglich der Analyse hyperspektraler 3D-Pflanzenmodelle, können sie dazu beitragen, das erkannte, jedoch noch unausgeschöpfte Potenzial hyperspektraler Bilder, zu erschließen.

Die nächsten Schritte werden die Integration aller eingeführten Methoden in einem Modell und die Validierung dieses Gesamtmodells anhand weiterer Experimente sein. Darüber hinaus wird die Entwicklung eines integrierten Sensor- und Analysesystems für hyperspektrale 3D-Pflanzenmodelle im Fokus stehen. Verbliebene Abweichungen der Kamerakalibrierung sind zu vernachlässigen, sodass als genauigkeitsbegrenzender Faktor die kontinuierliche Bewegung vitaler Pflanzen als Funktion der Zeit verbleibt. Um diesen nicht vorhersagbaren

Faktor zu minimieren, ist eine annähernd synchrone Messung erforderlich, die nur vollautomatisiert erfolgen kann. Für einen vollautomatischen Einsatz der referenzierten Sensoren in Hochdurchsatzanlagen ist neben einer kontinuierlichen und automatisierten Online-Kalibrierung eine stabile physische Kopplung der beiden Sensoren erforderlich.

Im Bereich Entwicklung neuer Analyseverfahren stellt der Mangel an anerkannten und verfügbaren Datensätzen zum qualitativen Vergleich unterschiedlicher Analyseverfahren ein Hemmnis dar. Im Bereich der Computer Vision und der Fernerkundung werden diese seit langem erfolgreich eingesetzt. Bekannt sind hier vor allem die hyperspektralen Datensätzen „Indian Pines“ und „Pavia University“. Im Bereich der Phänotypisierung werden erste Versuche in dieser Hinsicht unternommen (z.B. Scharr et al., 2014). Der nächste Schritt ist daher der Aufbau von Benchmark-Datensätzen auf Basis von hyperspektralen 3D-Pflanzenmodellen, die den Bereich Trockenstress und darüber hinaus auch verschiedene Krankheitssymptome abdecken. Da nur wenige Institutionen sowohl Zugriff auf Hyperspektralkameras, als auch auf 3D-Laserscanner haben, können derartige Datensätze die Entwicklung von Analyseverfahren wirkungsvoll unterstützen und somit die Anwendungsgebiete erweitern.

Fortschritte im Bereich der Phänotypisierung sind eng mit einer Erweiterung der Sensorbasis gekoppelt. Die Fusion mit ergänzenden Sensoren, auch aus dem Low-Cost-Bereich, liefert ein umfassenderes Gesamtbild der physiologischen Eigenschaften der Pflanze. Aufbauend auf den Erfahrungen mit den Low-Cost-Sensoren zur Geometrierfassung kann dieser Ansatz auf weitere Sensoren ausgedehnt werden. Je nach untersuchtem Prozess können weitere bildgebende und auch nicht bildgebende Sensordaten auf verschiedenen Skalen mit dem 3D-Modell fusioniert und als kombiniertes Objekt in einer geeigneten Datenbank für die Analyse gespeichert werden. Eine weitere erfolgversprechende Informationsebene ist die Verknüpfung von Semantik und Geometrie. Eine Klassifikation der Pflanzenorgane in Blatt, Stängel und ggf. Stamm (z.B. Wahabzada et al., 2015) und eine Einbeziehung in die Analyse als Merkmal höherer Ordnung kann die Interpretation der Daten bei vielen Pflanzensorten unterstützen. Auf Basis der Geometrie prädizierte Reflektanzeigenschaften der einzelnen Pflanzenorgane sind eine wertvolle Information, wenn Aspekte der Abschattung und Sekundärreflektion innerhalb der Pflanze betrachtet werden.

Temporal hochaufgelöste Zeitreihen derartig angereicherter und aggregierter Beobachtungen ermöglichen einen neuen, datengetriebenen und nicht-invasiven Zugang zu einem Prozessverständnis der pflanzlichen Stressreaktionen. In Kombination mit bereits vorhandenen funktionalen Wachstumsmodellen auf verschiedenen Skalen können sie die Grundlage für eine neue Form von datengetriebenen funktional-strukturellen Pflanzenmodellen (z.B. Godin und Sinoquet, 2005) darstellen. Auf diesem Weg können die Modelle und Methoden dieser Arbeit mit zur Bewältigung der großen Herausforderungen der Welternährung unter dem Einfluss des fortschreitenden Klimawandels beitragen.

Literaturverzeichnis

- Abdel-Aziz, Y.I.*, und *H.M. Karara*, 1971: Direct linear transformation from comparator coordinates into object space coordinates. In: American Society of Photogrammetry, Symposium on Close-Range Photogrammetry. Falls Church, Virginia, USA, S. 1–18.
- Achanta, R.*, *A. Shaji*, *K. Smith*, *A. Lucchi*, *P. Fua*, und *S. Süssstrunk*, 2010: SLIC superpixels. Techn. Ber. 149300, Eidgenössische Technische Hochschule Lausanne.
- Agresti, A.*, 2002: Categorical Data Analysis, 2nd Edition. John Wiley & Sons, New Jersey, USA.
- Bareth, G.*, *H. Aasen*, *J. Bendig*, *M.L. Gnyp*, *A. Bolten*, *A. Jung*, *R. Michels*, und *J. Soukkamäki*, 2015: Low-weight and UAV-based hyperspectral full-frame cameras for monitoring crops: spectral comparison with portable spectroradiometer measurements. *Photogrammetrie-Fernerkundung-Geoinformation* 1: 69–79.
- Behmann, J.*, *A.-K. Mahlein*, *T. Rumpf*, *C. Römer*, und *L. Plümer*, 2014a: A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture* 16: 239–260.
- Behmann, J.*, *P. Schmitter*, *J. Steinrücken*, und *L. Plümer*, 2014b: Ordinal classification for efficient plant stress prediction in hyperspectral data. *ISPRS Archives XL-7*: 29–36.
- Behmann, J.*, *J. Steinrücken*, und *L. Plümer*, 2014c: Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing* 93: 98–111.
- Behmann, J.*, *A.-K. Mahlein*, *S. Paulus*, *J. Dupuis*, *H. Kuhlmann*, *E.-C. Oerke*, und *L. Plümer*, 2015a: Generation and application of hyperspectral 3D plant models: methods and challenges. *Machine Vision and Applications* : 1–14(online first).
- Behmann, J.*, *A.-K. Mahlein*, *S. Paulus*, *H. Kuhlmann*, *E.-C. Oerke*, und *L. Plümer*, 2015b: Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping. *ISPRS Journal of Photogrammetry and Remote Sensing* 106: 172–182.
- Blackburn, G.A.*, 2007: Hyperspectral remote sensing of plant pigments. *Journal of Experimental Botany* 58: 855–867.
- Bousquet, L.*, *S. Lachérade*, *S. Jacquemoud*, und *I. Moya*, 2005: Leaf BRDF measurements and model for specular and diffuse components differentiation. *Remote Sensing of Environment* 98: 201–211.

- Brakke, T.W., J.A. Smith, und J.M. Harnden*, 1989: Bidirectional scattering of light from tree leaves. *Remote Sensing of Environment* 29: 175–183.
- Breiman, L.*, 2001: Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical Science* 16: 199–231.
- Bruce, L.M., C.H. Koger, und J. Li*, 2002: Dimensionality reduction of hyperspectral data using discrete wavelet transform feature extraction. *IEEE Transactions on Geoscience and Remote Sensing* 40: 2331–2338.
- Chapelle, O., und V. Vapnik*, 2000: Model selection for support vector machines. *Advances in Neural Information Processing Systems* 12: 230–236.
- Chu, W., und S. Keerthi*, 2007: Support vector ordinal regression. *Neural Computation* 19: 792–815.
- Clarke, T., und J. Fryer*, 1998: The development of camera calibration methods and models. *The Photogrammetric Record* 16: 51–66.
- Comar, A., F. Baret, F. Viénot, L. Yan, und B. de Solan*, 2012: Wheat leaf bidirectional reflectance measurements: Description and quantification of the volume, specular and hot-spot scattering features. *Remote Sensing of Environment* 121: 26–35.
- Cortes, C., und V. Vapnik*, 1995: Support-vector networks. *Machine learning* 20: 273–297.
- CROP.SENSE.net*, 2014: Informationsbroschüre: CROP.SENSE.net - Kompetenznetzwerk für Phänotypisierungsforschung - Sensortechnologie für Pflanzenzüchtung und Bestandsmanagement. online verfügbar unter <https://www.cropsense.uni-bonn.de/broschuere-cropsense-de-druck.pdf>. (abgerufen am 15.01.2015).
- Datt, B.*, 1999: A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using eucalyptus leaves. *Journal of Plant Physiology* 154: 30–36.
- Frank, E., und M. Hall*, 2001: A simple approach to ordinal classification. In: *Luc Raedt und Peter Flach* (Hg.), *Machine Learning: ECML 2001: 12th European Conference on Machine Learning* Freiburg, Germany, September 5–7, 2001. Berlin, Heidelberg: Springer, S. 145–156.
- Furbank, R.T., und M. Tester*, 2011: Phenomics—technologies to relieve the phenotyping bottleneck. *Trends in Plant Science* 16: 635–644.
- Godin, C., und H. Sinoquet*, 2005: Functional—structural plant modelling. *New Phytologist* 166: 705–708.
- Gupta, R., und R.I. Hartley*, 1997: Linear pushbroom cameras. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 19: 963–975.
- Guyon, I., und A. Elisseeff*, 2003: An introduction to variable and feature selection. *The Journal of Machine Learning Research* 3: 1157–1182.

- Joachims, T.*, 2006: Training linear SVMs in linear time. In: Proceedings of the 12th SIGKDD. Philadelphia, USA: ACM, S. 217–226.
- Kassalainen, S., O. Nevalainen, T. Hakala, und K. Antilla*, 2016: Incidence Angle Dependency of leaf Vegetation Indices from Hyperspectral Lidar Measurements. *Photogrammetrie-Fernerkundung-Geoinformation 2*: 75–84.
- Khoshelham, K., und S.O. Elberink*, 2012: Accuracy and resolution of kinect depth data for indoor mapping applications. *Sensors 12*: 1437–1454.
- Lafferty, J.D., A. McCallum, und F.C.N. Pereira*, 2001: Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data. In: Proceedings of the 18th International Conference on Machine Learning, ICML '01. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., S. 282–289.
- Lee, D.W.*, 2002: Anthocyanins in autumn leaf senescence. *Advances in Botanical Research 37*: 147–165.
- Merzlyak, M.N., A.A. Gitelson, O.B. Chivkunova, und V.Y. Rakitin*, 1999: Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum 106*: 135–141.
- Minervini, M., H. Scharr, und S.A. Tsafaris*, 2015: Image Analysis: The New Bottleneck in Plant Phenotyping. *IEEE Signal Processing Magazine 32*: 126–131.
- Paulus, S., J. Behmann, A.-K. Mahlein, L. Plümer, und H. Kuhlmann*, 2014a: Low-cost 3D systems - well suited tools for plant phenotyping. *Sensors 14*: 3001–3018.
- Paulus, S., H. Schumann, J. Léon, und H. Kuhlmann*, 2014b: A high precision laser scanning system for capturing 3D plant architecture and analysing growth of cereal plants. *Biosystems Engineering 121*: 1–11.
- Raza, S.-A., G. Prince, J.P. Clarkson, und N.M. Rajpoot*, 2015: Automatic detection of diseased tomato plants using thermal and stereo visible light images. *PLoS ONE 10*: e0123262.
- Römer, C., K. Bürling, Pl. Hunsche, T. Rumpf, G. Noga, und L. Plümer*, 2011: Robust fitting of fluorescence spectra for pre-symptomatic wheat leaf rust detection with support vector machines. *Computers and Electronics in Agriculture 79*: 180–188.
- Römer, C., M. Wahabzada, A. Ballvora, F. Pinto, M. Rossini, C. Panigada, J. Behmann, J. Léon, C. Thurau, C. Bauckhage, K. Kersting, U. Rascher, und L. Plümer*, 2012: Early drought stress detection in cereals: simplex volume maximisation for hyperspectral image analysis. *Functional Plant Biology 39*: 878–890.
- Roscher, R., J. Behmann, A.-K. Mahlein, J. Dupuis, H. Kuhlmann, und L. Plümer*, 2016a: Detection of Disease Symptoms on Hyperspectral 3D Plant Models. *ISPRS Annals III-7*: 89–96. (equal contribution).

- Roscher, R., J. Behmann, A.-K. Mahlein, und L. Plümer*, 2016b: On the benefit of topographic dictionaries for detecting disease symptoms on hyperspectral 3D plant models. In: 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). (accepted).
- Rouse, J. W., R.H. Haas, J.A. Schell, und Deering D.W.*, 1974: Monitoring vegetation systems in the Great Plains with ERTS. In: *S.C. Freden* (Hg.), 3rd Earth Resources Technology Satellite Symposium. NASA. Goddard Space Flight Center, S. 309–317.
- Rumpf, T., A.-K. Mahlein, D. Dörschlag, und L. Plümer*, 2009: Identification of combined vegetation indices for the early detection of plant diseases. In: *C. M.U. Neale und A. Maltese* (Hg.), Proceedings of SPIE 7472, Remote Sensing for Agriculture, Ecosystems, and Hydrology XI, 747217.
- Rumpf, T., A.-K. Mahlein, U. Steiner, E.C. Oerke, H.W. Dehne, und L. Plümer*, 2010: Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture* 74: 91–99.
- Scharr, H., M. Minervini, A. Fischbach, und S.A. Tsafaris*, 2014: Annotated image datasets of rosette plants. Techn. Ber. FZJ-2014-03837, Forschungszentrum Jülich.
- Schölkopf, B., und A.J. Smola*, 2002: Learning with kernels: support vector machines, regularization, optimization, and beyond. MIT press.
- Stagakis, S., V. González-Dugo, P. Cid, M.L. Guillén-Climent, und P.J. Zarco-Tejada*, 2012: Monitoring water stress and fruit quality in an orange orchard under regulated deficit irrigation using narrow-band structural and physiological remote sensing indices. *ISPRS Journal of Photogrammetry and Remote Sensing* 71: 47–61.
- Taiz, L., und E. Zeiger*, 2010: Plant Physiology. Sinauer Associates, Inc., 5. Aufl.
- Tarnavsky, E., S. Garrigues, und M.E. Brown*, 2008: Multiscale geostatistical analysis of AVHRR, SPOT-VGT, and MODIS global NDVI products. *Remote Sensing of Environment* 112: 535–549.
- Tax, D.M.J., und R.P.W. Duin*, 2004: Support vector data description. *Machine Learning* 54: 45–66.
- Thenkabail, P.S., R.B. Smith, und E. de Pauw*, 2000: Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment* 71: 158–182.
- Vapnik, V.N.*, 1998: Statistical Learning Theory. Wiley-Interscience.
- Wahabzada, M., S. Paulus, K. Kersting, und A.-K. Mahlein*, 2015: Automated interpretation of 3D laserscanned point clouds for plant organ segmentation. *BMC Bioinformatics* 16: 248.
- Williams, R.*, 2006: Generalized ordered logit/partial proportional odds models for ordinal dependent variables. *The Stata Journal* 6: 58–82.

- Winkelbach, S., S. Molkenstruck, und F.M. Wahl*, 2006: Low-Cost Laser Range Scanner and Fast Surface Registration Approach. In: *K. Franke, K.-R. Müller, B. Nickolay, und R. Schäfer* (Hg.), Proceedings of the DAGM Symposium, Berlin,. Springer, S. 718–728.
- Zarco-Tejada, P.J., J.R. Miller, T.L. Noland, G.H. Mohammed, und P.H. Sampson*, 2001: Scaling-up and model inversion methods with narrowband optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing* **39**: 1491–1507.

A Auflistung der eigenen Publikationen

A.1 Auflistung der beigefügten Publikationen

Die folgenden Publikationen sind zentral für diese Arbeit und im Anhang B beigefügt (thematisch geordnet).

Behmann, J., A.-K. Mahlein, T. Rumpf, C. Römer, und L. Plümer, 2014: A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, 16, 239–260. (equal contribution)

Behmann, J., J. Steinrücken, und L. Plümer, 2014: Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 98–111.

Paulus, S., *J. Behmann*, A.-K. Mahlein, L. Plümer, und H. Kuhlmann, 2014: Low-cost 3D systems: suitable tools for plant phenotyping. *Sensors*, 14, 3001–3018. (equal contribution)

Behmann, J., A.-K. Mahlein, S. Paulus, H. Kuhlmann, E.-C. Oerke, und L. Plümer, 2015: Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 172–182.

Behmann, J., A.-K. Mahlein, S. Paulus, J. Dupuis, H. Kuhlmann, E.-C. Oerke, und L. Plümer, 2015: Generation and application of hyperspectral 3D plant models: methods and challenges. *Machine Vision and Applications*, 1–14. (online first)

Roscher, R., *J. Behmann*, A.-K. Mahlein, J. Dupuis, H. Kuhlmann, und L. Plümer, 2016: Detection of disease symptoms on hyperspectral 3D plant models, *ISPRS Annals*, III-7, 89–96. (equal contribution)

A.2 Auflistung der übrigen Publikationen

Behmann, J., A.-K. Mahlein, S. Paulus, H. Kuhlmann, E.-C. Oerke, und L. Plümer, 2014: Generation and application of hyperspectral 3D plant models, In: Agapito, Lourdes (Hg.): *Computer Vision - ECCV 2014 Workshops: Lecture Notes in Computer Science*, 8928, S. 117–130.

Behmann, J., A.-K. Mahlein, und L. Plümer, 2015: Early Identification of Plant Stress in Hyperspectral Images, In: Fritsch, Dieter (Hg.): *Photogrammetric Week 2015*. S. 317–327

- Behmann, J.*, K. Hendriksen, U. Müller, W. Büscher, und L. Plümer, 2016: Support Vector machine and duration-aware conditional random field for identification of spatio-temporal activity patterns by combined indoor positioning and heart rate sensors, *GeoInformatica*, 1-22. (online first)
- Behmann, J.*, P. Schmitter, J. Steinrücken, A. Ballvora, A.-K. Mahlein, und L. Plümer, 2015: Detektion von Pflanzenstress in hyperspektralen Bildern im Nahbereich, In: Kersten, T. P. (Hg.): *Bridging Scales -Skalenübergreifende Nah- und Fernerkundungsmethoden*, 35. Wissenschaftlich-Technische Jahrestagung der DGPF, Köln, S. 216–225.
- Behmann, J.*, P. Schmitter, J. Steinrücken, und L. Plümer, 2014: Ordinal classification for efficient plant stress prediction in hyperspectral data, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-7, 29–36.
- Dupuis, J., S. Paulus, *J. Behmann*, L. Plümer, und H. Kuhlmann, 2014: A multi-resolution approach for an automated fusion of different low-cost 3D sensors, *Sensors*, 14, 7563–7579.
- Römer, C., A. Rodionov, *J. Behmann*, S. Pätzold, G. Welp, und L. Plümer, 2014: Quantifying moisture and roughness with Support Vector Machines improves spectroscopic soil organic carbon prediction, *Journal of Plant Nutrition and Soil Science*, 177, 845–847.
- Römer, C., M. Wahabzada, A. Ballvora, F. Pinto, M. Rossini, *J. Behmann*, J. Léon, C. Thureau, C. Bauckhage, K. Kersting, U. Rascher, und L. Plümer, 2012: Early drought stress detection in cereals: simplex volume maximization for hyperspectral image analysis, *Functional Plant Biology*, 39, 878–890.
- Roscher, R., *J. Behmann*, A.-K. Mahlein, und L. Plümer, 2016: On the benefit of topographic dictionaries for detecting disease symptoms on hyperspectral 3D plant models. 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), IEEE (accepted)
- Schmitter, P., *J. Behmann*, J. Steinrücken, A.-K. Mahlein, E.-C. Oerke, und L. Plümer, 2015: Aktives Lernen zur Detektion von Pflanzenkrankheiten in hyperspektralen Bildern, In: Kersten, T. P. (Hg.): *Bridging Scales -Skalenübergreifende Nah- und Fernerkundungsmethoden*, 35. Wissenschaftlich-Technische Jahrestagung der DGPF, Köln, S. 398–406.

B Beigefügte Publikationen

B.1 A review of advanced machine learning methods for the detection of biotic stress in precision crop protection

Behmann, J., A.-K. Mahlein, T. Rumpf, C. Römer, und L. Plümer, 2014: A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, 16, 239-260. (equal contribution)

Abstract

Effective crop protection requires early and accurate detection of biotic stress. In recent years, remarkable results have been achieved in the early detection of weeds, plant diseases and insect pests in crops. These achievements are related both to the development of non-invasive, high resolution optical sensors and data analysis methods that are able to cope with the resolution, size and complexity of the signals from these sensors. Several methods of machine learning have been utilized for precision agriculture such as support vector machines and neural networks for classification (supervised learning); k-means and self-organizing maps for clustering (unsupervised learning). These methods are able to calculate both linear and non-linear models, require few statistical assumptions and adapt flexibly to a wide range of data characteristics. Successful applications include the early detection of plant diseases based on spectral features and weed detection based on shape descriptors with supervised or unsupervised learning methods. This review gives a short introduction into machine learning, analyses its potential for precision crop protection and provides an overview of instructive examples from different fields of precision agriculture.

Aus Copyright-Gründen ist die vollständige Publikation nur in der Druckversion enthalten.

B.2 Detection of early plant stress responses in hyperspectral images

Behmann, J., J. Steinrücken, und L. Plümer, 2014: Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 98-111.

Abstract

Early stress detection in crop plants is highly relevant, but hard to achieve. We hypothesize that close range hyperspectral imaging is able to uncover stress related processes non-destructively in the early stages which are invisible to the human eye. We propose an approach which combines unsupervised and supervised methods in order to identify several stages of progressive stress development from series of hyperspectral images. Stress of an entire plant is detected by stress response levels at pixel scale. The focus is on drought stress in barley (*Hordeum vulgare*). Unsupervised learning is used to separate hyperspectral signatures into clusters related to different stages of stress response and progressive senescence. Whereas all such signatures may be found in both, well watered and drought stressed plants, their respective distributions differ. Ordinal classification with Support Vector Machines (SVM) is used to quantify and visualize the distribution of progressive stages of senescence and to separate well watered from drought stressed plants. For each senescence stage a distinctive set of most relevant Vegetation Indices (VIs) is identified. The method has been applied on two experiments involving potted barley plants under well watered and drought stress conditions in a greenhouse. Drought stress is detected up to ten days earlier than using NDVI. Furthermore, it is shown that some VIs have overall relevance, while others are specific to particular senescence stages. The transferability of the method to the field is illustrated by an experiment on maize (*Zea mays*).

Aus Copyright-Gründen ist die vollständige Publikation nur in der Druckversion enthalten.

B.3 Low-cost 3D systems: suitable tools for plant phenotyping

Paulus, S., J. Behmann, A.-K. Mahlein, L. Plümer, und H. Kuhlmann, 2014: Low-cost 3D systems: suitable tools for plant phenotyping. *Sensors*, 14, 3001-3018. (equal contribution)

Abstract

Over the last few years, 3D imaging of plant geometry has become of significant importance for phenotyping and plant breeding. Several sensing techniques, like 3D reconstruction from multiple images and laser scanning, are the methods of choice in different research projects. The use of RGBcameras for 3D reconstruction requires a significant amount of post-processing, whereas in this context, laser scanning needs huge investment costs. The aim of the present study is a comparison between two current 3D imaging low-cost systems and a high precision close-up laser scanner as a reference method. As low-cost systems, the David laser scanning system and the Microsoft Kinect Device were used. The 3D measuring accuracy of both low-cost sensors was estimated based on the deviations of test specimens. Parameters extracted from the volumetric shape of sugar beet taproots, the leaves of sugar beets and the shape of wheat ears were evaluated. These parameters are compared regarding accuracy and correlation to reference measurements. The evaluation scenarios were chosen with respect to recorded plant parameters in current phenotyping projects. In the present study, low-cost 3D imaging devices have been shown to be highly reliable for the demands of plant phenotyping, with the potential to be implemented in automated application procedures, while saving acquisition costs. Our study confirms that a carefully selected low-cost sensor is able to replace an expensive laser scanner in many plant phenotyping scenarios.

Aus Copyright-Gründen ist die vollständige Publikation nur in der Druckversion enthalten.

B.4 Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping

Behmann, J., A.-K. Mahlein, S. Paulus, H. Kuhlmann, E.-C. Oerke, und L. Plümer, 2015: Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 172-182.

Abstract

Hyperspectral sensors are able to detect biological processes of plants which are invisible to the naked eye. Close-range cameras in particular support the identification of biotic and abiotic stress reactions at an early stage. Up to now, their full potential is only partially realized because geometrical factors as leaf angle, curvature and self-shading, overlay the signal of biological processes. Suitable 3D plant models constitute an important step to removing these factors from the data. The matching of these 3D model and the hyperspectral image with sufficient accuracy even for small leaf veins is required but relies on an adequate geometric calibration of hyperspectral cameras. We present a method for the geometric calibration of hyperspectral pushbroom cameras in the close-range, which enables reliable and reproducible results at sub-pixel scale. This approach extends the linear pushbroom camera by the ability to model non-linear fractions. Accuracy and reproducibility of the method is validated using a hyperspectral sensor system with two line cameras observing the reflected radiation in the spectral range from 400 to 2500 nm. We point out new potentials arising from with the proposed camera calibration, e.g. hyperspectral 3D plant models, which have high potential for crop plant phenotyping.

Aus Copyright-Gründen ist die vollständige Publikation nur in der Druckversion enthalten.

B.5 Generation and application of hyperspectral 3D plant models: methods and challenges

Behmann, J., A.-K. Mahlein, S. Paulus, J. Dupuis, H. Kuhlmann, E.-C. Oerke, und L. Plümer, 2015: Generation and application of hyperspectral 3D plant models: methods and challenges. *Machine Vision and Applications*, 1-14. (online first)

Abstract

Hyperspectral imaging sensors have been introduced for measuring the health status of plants. Recently, they also have been used for close-range sensing of plant canopies with a highly complex architecture. However, the complex geometry of plants and their interaction with the illumination setting severely affect the spectral information obtained. Furthermore, the spatial component of analysis results gain in importance as higher plants are represented by multiple plant organs as leaves, stems and seed pods. The combination of hyperspectral images and 3D point clouds is a promising approach to face these problems. We present the generation and application of hyperspectral 3D plant models as a new, interesting application field for computer vision with a variety of challenging tasks. We sum up a geometric calibration method for hyperspectral pushbroom cameras using a reference object for the combination of spectral and spatial information. Furthermore, we show exemplarily new calibration and analysis methods enabled by the hyperspectral 3D models in an experiment with sugar beet plants. An improved normalization, a comparison of image and 3D analysis and the density estimation of infected surface points underline some of the new capabilities gained using this new data type. Based on such hyperspectral 3D models the effects of plant geometry and sensor configuration can be quantified and modeled. In future, reflectance models can be used to remove or weaken the geometry-related effects in hyperspectral images and, therefore, have the potential to improve automated plant phenotyping significantly.

Aus Copyright-Gründen ist die vollständige Publikation nur in der Druckversion enthalten.

B.6 Detection of disease symptoms on hyperspectral 3D plant models

Roscher, R., J. Behmann, A.-K. Mahlein, J. Dupuis, H. Kuhlmann, und L. Plümer, 2016: Detection of disease symptoms on hyperspectral 3D plant models, ISPRS Annals, III-7, 89-96. (equal contribution)

Abstract

We analyze the benefit of combining hyperspectral images information with 3D geometry information for the detection of *Cercospora* leaf spot disease symptoms on sugar beet plants. Besides commonly used one-class Support Vector Machines, we utilize an unsupervised sparse representation-based approach with group sparsity prior. Geometry information is incorporated by representing each sample of interest with an inclination-sorted dictionary, which can be seen as an 1D topographic dictionary. We compare this approach with a basic sparse representation based approach without geometry information and one-class Support Vector Machines. The one-class SVM is applied on hyperspectral data without additional information as well as on a hyperspectral images with additional pixelwise inclination information. Our results show a gain in accuracy when using geometry information beside spectral information regardless of the used approach. However, the two methods make different demands on the data when applied to new test data sets. The OCSVM requires the full inclination information on test and training data whereas the topographic dictionary approach only need spectral information for reconstruction of test data once the dictionary is build by spectra with inclination.

Aus Copyright-Gründen ist die vollständige Publikation nur in der Druckversion enthalten.

Danksagung

Ich möchte mich an dieser Stelle bei allen bedanken, die mir bei der Erstellung der Dissertation zur Seite gestanden haben.

Für die Möglichkeit an der Thematik zu arbeiten und die Unterstützung während der letzten Jahre bei meiner Arbeit, insbesondere jedoch bei der Anfertigung dieser Thesis, möchte ich mich im Besonderen bei Prof. Dr. Lutz Plümer bedanken. Ebenfalls möchte ich mich bei Prof. Dr.-Ing. Heiner Kuhlmann und Dr. Hanno Scharr bedanken für die Bereitschaft das Koreferat für meine Dissertation zu übernehmen.

Ich möchte mich weiterhin bei meinen Kollegen vom Institut für Geodäsie und Geoinformation für die Unterstützung und die kollegiale Zusammenarbeit bedanken. Im Besonderen gilt mein Dank Prof. Dr. Ribana Roscher, Dr. Christoph Römer und Youness Dehbi für die kritischen Anmerkungen und Anregungen für die vorliegende Arbeit, sowie Michael Kneuper und Stefan Teutsch für die stets große Hilfsbereitschaft bei der Erstellung und Überarbeitung der Grafiken in dieser Thesis.

Abschließend möchte ich mich noch bei allen Kollegen und Projektpartnern aus CROP.SENSE.net für die vertrauensvolle und hilfreiche Zusammenarbeit bedanken. Insbesondere Dr. Anne-Katrin Mahlein, Stefan Paulus und Jan Dupuis haben durch die Kooperation die Dissertation in der vorliegenden Form erst ermöglicht. Beim Land NRW und EFRE bedanke ich mich für die Finanzierung dieser Arbeit über das Forschungsprojekt 005-1103-0018 / Ziel 2-Programm CROP.SENSE.net

Die Unterstützung meiner Familie kann ich nicht genug hervorheben. Meine Eltern haben mir dieses Studium ermöglicht. Meine Frau hat mir insbesondere zum Schluss meines Promotionsstudiums den Rücken frei gehalten und mich von jeder zusätzlichen Belastung abgeschirmt. Meine Tochter hat mir durch ihren robusten Nachtschlaf die nötige Erholung ermöglicht. Dafür möchte ich euch danken.