

Musterbasierte Bildanalyse der Bewirtschaftungsrichtung landwirtschaftlicher Flächen

Pattern-Based Image Analysis of Agricultural Land Management Direction

Simone Aigner | Andreas Schmitt

Zusammenfassung

Durch Bodenerosion geht jeden Tag wertvolle Ackererde verloren. Die Erosionsgefahr pro Feldstück wird anhand mehrerer Faktoren ermittelt und im sogenannten Erosionsatlas, welcher für Bayern auch fortschreitend aktualisiert wird, gesammelt dargestellt. Ein Bestandteil ist der Querbewirtschaftungsfaktor – oder auch P-Faktor genannt –, der derzeit durch einen bayernweit einheitlichen Wert repräsentiert wird. Zur lokalen Anpassung des P-Faktors ist eine flächendeckende Ableitung der Bewirtschaftungsrichtung notwendig. Für deren vollautomatische Erkennung werden in dieser Studie die multidirektionalen Filtermasken der Schmittlets zu SmoothSlets, DiffSlets und CurvedSlets weiterentwickelt, um für jedes Bildpixel im Orthophoto eine Richtungsinformation zu erhalten, welche anschließend über ein gesamtes Feldstück aggregiert in die vorherrschende Bewirtschaftungsrichtung überführt wird. Die ermittelte Bewirtschaftungsrichtung wird abschließend zusammen mit weiteren Parametern zur lokalen Anpassung des P-Faktors exemplarisch in einer digitalen Bestandskarte illustriert.

Schlüsselwörter: Bodenerosion, Bewirtschaftungsrichtung, hangparallele Bewirtschaftung, Schmittlets

Summary

Every day, valuable arable soil is lost through soil erosion. The erosion risk per land parcel is determined on the basis of several factors and gathered in the so-called erosion atlas, which is progressively updated in the case of Bavaria. One component is the cross-direction cultivation factor – or simply P-factor – which is currently represented by a uniform value for the whole of Bavaria. The local adaptation of the P-factor requires an area-wide derivation of the prevalent cultivation direction. In this study the multidirectional filter masks of Schmittlets are further developed to SmoothSlets, DiffSlets and CurvedSlets to obtain directional information for each pixel of an digital orthophoto, which is then aggregated over an entire field piece and transformed into the prevalent cultivation direction. In this way, the cultivation direction can be determined fully automatically over large coverages. This study results in an area-wide digital map where the derived cultivation direction is illustrated together with further parameters as a basis for the future local adjustment of the P-factor.

Keywords: Soil Erosion, Cultivation Direction, Slope-parallel Cultivation, Schmittlets

1 Einleitung

Nicht nur die – durch ihre Medienpräsenz allseits diskutierten – Starkregenereignisse, sondern jeder einzelne Regenschauer trägt Tropfen für Tropfen die obere Bodenschicht ab, wenn diese nicht durch Vegetation geschützt ist und das abfließende Wasser somit filtriert wird. In der gesamten EU sind ca. 12 Millionen Hektar Ackerflächen von Erosion betroffen. Diese Flächen verlieren im Jahr ca. 970 Millionen Tonnen wertvollen Humus und damit einhergehend auch 0,43 % an Pflanzenproduktivität. Der Verlust kostet die Landwirtschaft jährlich ca. 1,25 Milliarden Euro (Panagos et al. 2018). Pro Hektar wird der Verlust von fruchtbarem Boden in Europa auf ca. 2,5 t geschätzt, was bei einer durchschnittlichen Neubildung von nur ca. 1,4 t pro Jahr zu einer kontinuierlichen und unwiederbringlichen Abnahme von fruchtbarem Ackerboden führt (Panagos et al. 2015). Diesem Prozess kann ausschließlich mit präventiven Maßnahmen begegnet werden. Dazu zählen beispielsweise die Umstellung auf eine hangparallele Bewirtschaftung, die Einbringung bestimmter Strukturen wie Hecken oder Feldgehölze im Rahmen von Flurneuerungsverfahren sowie eine an die Hanglage angepasste, erosionsabmildernde Fruchtfolge (Oberholzer 1985).

Aus diesem Grund soll bei Verfahren der Ländlichen Entwicklung – zum Beispiel bei der Wegnetzplanung – darauf geachtet werden, dass bei der Neuzuteilung eine hangparallele Bewirtschaftung ermöglicht wird, die für den Landwirt auch attraktiv ist (StMELF 2005). Im Bereich der Ländlichen Entwicklung ist das Wissen über die vorherrschende Bewirtschaftungsrichtung durch Ortsbegehung und Bürgerbeteiligung ausreichend vorhanden. Betrachtet man jedoch eine flächendeckende Ausweisung der Erosionsgefahr z. B. im Erosionsatlas Bayern der Bayerischen Landesanstalt für Landwirtschaft, der den zu erwartenden mittleren Bodenabtrag von Ackerflächen unter Berücksichtigung mehrerer Faktoren für den gesamten Freistaat Bayern angibt (StMELF 2022), sind moderne Verfahren zur flächendeckenden Ableitung der benötigten Eingangsgrößen gefordert. Einer dieser Faktoren ist der sogenannte P-Faktor (Querbewirtschaftungsfaktor), welcher abhängig von Hanglänge, Hangneigung und vorliegender Querbewirtschaftung – also einer erosionsabmildernden Bewirtschaftung quer zur Hangneigung – angegeben wird (siehe Abb. 1). Es ist bekannt, dass eine Bewirtschaftung quer zum Gefälle die Erosionsgefahr reduziert, da bei nicht zu

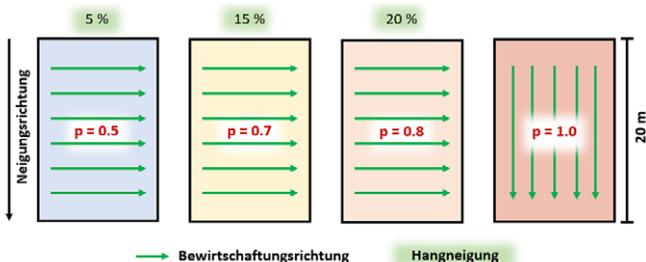


Abb. 1: P-Faktor für ein Hangfeldstück mit 20 m Hanglänge und unterschiedlicher Neigung bei Querbewirtschaftung und bei Längsbewirtschaftung. Während die Längsbewirtschaftung, unabhängig der Hangneigung, keinerlei erosionsabmildernde Wirkung zeigt, kann mit Querbewirtschaftung bei nicht allzu großer Hangneigung die Erosion halbiert werden.

großer Hanglänge das Wasser abgebremst wird. Jedoch ist die Bestimmung des P-Faktors nicht ganz so einfach, da er sich aus der Kombination der – primär unbekannt – Bewirtschaftungsrichtung mit der Hangneigung und der Hanglänge gemäß Tab. 1 ergibt, welche in Abb. 2 zusätzlich visuell dargestellt ist. Je kleiner der P-Faktor, desto stärker die erosionsabmildernde Wirkung. Bei Überschreitung der maximalen Hangneigung oder bei Bewirtschaftung in Gefällerrichtung wird der P-Faktor auf den Maximalwert 1 gesetzt, d.h. keine erosionsabmildernde Wirkung durch Querbewirtschaftung (LfL 2019).

Da Hangneigung und Hanglänge dem bayernweit verfügbaren Digitalen Geländemodell entnommen werden können, ist nur noch die jeweilige Bewirtschaftungsrichtung quer oder längs des Gefälles zu ermitteln. Im Erosionsatlas Bayern fehlt genau diese Information der Bewirtschaftungsrichtung, um somit einen lokal angepassten

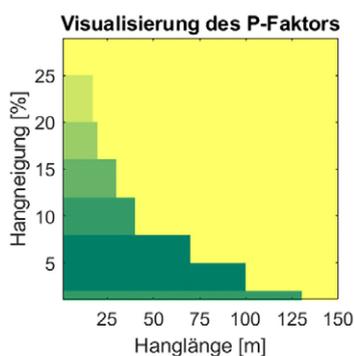


Abb. 2: Visuelle Darstellung des P-Faktors in Abhängigkeit von Hangneigung und Hanglänge gemäß Tab. 1.

Tab. 1: P-Faktor in Abhängigkeit von Hangneigung und Hanglänge (LfL 2019) bei vorliegender Querbewirtschaftung

Hangneigung [%]	Max. Hanglänge [m]	P-Faktor
1–2	130	0,6
3–5	100	0,5
6–8	70	0,5
9–12	40	0,6
13–16	30	0,7
17–20	20	0,8
21–25	17	0,9

P-Faktor bestimmen zu können. Deshalb wurde hier ein durchschnittlicher Wert von 0,85 angesetzt (Kagerer und Auerswald 1997), der heutzutage aufgrund veränderter Feldstrukturen vermutlich höher liegen dürfte. Ebenso einleuchtend ist, dass dieser Wert vom Main bis zur Zugspitze nicht identisch sein kann. Der Erosionsatlas Hessen setzt aufgrund fehlender Informationen über die Bewirtschaftung ebenfalls einen Einheitswert von 1, was dem Maximalwert entspricht (HLNUG 2023), d.h. es wird von keiner erosionsabmildernden Wirkung der Bewirtschaftung ausgegangen.

Der in dieser Studie implementierte Prozessor soll jeweils auf Basis der Feldstücke die vorherrschende Bewirtschaftungsrichtung aus bereitgestellten Digitalen Orthophotos vollautomatisch und ohne vorheriges Training bestimmen. Somit könnten in einem ersten Schritt regional, aber später auch bayernweit digitale Karten der tatsächlichen Bewirtschaftungsrichtung erstellt werden, um diese in einem zweiten Schritt mit dem Digitalen Geländemodell zu verschneiden. Die Hanglänge und Hangneigung werden in der aktuellen Studie als bekannt vorausgesetzt. Wenn man bedenkt, dass 65 % der Fläche des Freistaats Bayern – dies sind ca. 2 Millionen Hektar – agrarwirtschaftlich genutzt werden, wird deutlich, welche Bedeutung eine flächendeckend möglichst akkurate Modellierung der Erosionsgefahr hat (StMELF 2022).

2 Stand der Technik

Die Bewirtschaftungsrichtung zeichnet sich durch Reifenspuren im Acker ab. Um diese zuverlässig erfassen zu können, dürfen die Bodenpixel nach dem Nyquist-Shannon-Theorem nicht größer als maximal die halbe Reifenbreite sein. Satellitensensoren fallen aufgrund dieser Anforderung schon bis auf wenige, extrem kostspielige Ausnahmen weg. Nur Flugzeug- bzw. UAV-getragene Sensoren können derzeit diese räumliche Auflösung liefern. In Bayern bietet sich dafür das im zweijährigen Abstand aus Flugzeug-getragenen Aufnahmen flächendeckend neu erstellte Digitale Orthophoto DOP20 mit 20 cm Bodenpixeln an. Ferner können zur Verdichtung der Zeitreihe je nach Bedarf lokal zusätzliche Befliegungen mit einem UAV stattfinden. Von beiden Sensorplattformen werden beim Überflug streifenweise einzelne Bilder aufgenommen, welche anschließend zu einem großen Mosaik zusammengefügt werden. Da die Beleuchtung zwischen Flugstreifen variieren kann, muss die Radiometrie zwischen benachbarten Aufnahmen angepasst werden, was dazu führt, dass die absolute Radiometrie des Orthophotos verfälscht wird und somit die Reflektanzwerte im Bild nicht verlässlich sind (Pammer 2015).

Lokale Helligkeitsunterschiede zwischen benachbarten Pixeln sind jedoch sehr gut auswertbar. Beispielsweise ist ein einfacher, aus Binomialkoeffizienten zusammengesetzter Kantenfilter wie der Sobel-Operator bereits in der Lage, vertikale und horizontale Helligkeitsunterschiede entlang von Kanten im Bild hervorzuheben. Da sich der

Sobel-Operator jedoch auf eine 3×3 -Pixelumgebung beschränkt, ist eine feinere Auflösung der Richtung nur bei Kombination der vertikalen und horizontalen Kantenoperatoren möglich und extrem rauschanfällig (Werner 2021). Das Erkennen weitläufiger Kanten bzw. großflächiger Muster in Bildern wäre prinzipiell mit den Gray-Level Co-Occurrence Matrizen (GLCM) möglich. Trotz der variablen Patchgröße beschränken sich GLCMs in der Regel auf vertikale, horizontale und diagonale Muster (Haralick et al. 1973). Auch diese Winkelauflösung ist für unsere Anwendung noch zu grob, da sowohl Bewirtschaftungsrichtung als auch Hangneigung im Landeskoordinatensystem prinzipiell jeden beliebigen Richtungswinkel einnehmen können. Nachdem heutzutage in allen Bereichen die Möglichkeit der Nutzung künstlicher Intelligenz in Betracht gezogen wird, soll dies als Methode ebenfalls nicht außer Acht gelassen werden. Jedoch muss beispielsweise bei der Nutzung von Convolutional Neural Networks (CNN) darauf geachtet werden, möglichst viele verschiedene Referenzdaten zu verwenden, um ein zuverlässiges Neuronales Netz trainieren zu können. Optimalerweise muss jede Bewirtschaftungsrichtung mit jeder Feldfrucht mehrfach im Trainingsdatensatz vorkommen, was wiederum Methoden der Data Augmentation erfordert (Pawara et al. 2017).

Denn ein Ground-Truth-Datensatz in der geforderten Größe steht schlichtweg nicht zur Verfügung und wäre für die anvisierte Detektion der Bewirtschaftungsrichtung, welche sich meist schon bei visueller Betrachtung klar abzeichnet, auch nicht wirtschaftlich realisierbar. Eine Idee aus dem Bereich der CNNs kann aber durchaus aufgegriffen werden: die Erkennung von Objekten im Bild auf Basis zahlreicher Faltungen mit unterschiedlichen – im Falle von CNN zufällig zusammengestellten – Filterkernen (O’Shea und Nash 2015). Wenn statt der zufälligen Filtermasken die Kerne gezielt definiert werden, erschließt sich das breite Spektrum der Multi-Rate-Filterbanks und der alternativen Bilddarstellungen (Do und Lu 2011). Beide Ansätze gehen davon aus, dass wiederkehrende Strukturen in einem Bild an verschiedenen Orten, in verschiedenen Größen und in verschiedenen Orientierungen vorkommen können. Während die Multi-Rate-Filterbanks darauf abzielen, diese Strukturen zu extrahieren, versuchen die alternativen Bild Darstellungen, das Bild auf Basis vordefinierter Strukturen zu rekonstruieren. Gerade die alternativen Bild Darstellungen haben sich dabei als auffallend robust gegenüber Unschärfe oder Rauschen erwiesen, selbst wenn rein visuell keine Strukturen mehr im Bild zu erkennen sind (Candès und Donoho 1999).

Das wohl bekannteste Beispiel für eine alternative Bild Darstellung ist die Transformation in den Frequenzraum mittels diskreter Fourier-Transformation. Die Fourier-Analyse kann über die zweidimensionale Fast-Fourier-Transformation schnell auf Bilder angewendet werden, hat aber bereits in ihrer analytischen Definition einen grundlegenden Nachteil: Die Schwingungen haben per Definition eine unendliche Ausdehnung. Randeffekte werden zwar üblicherweise über Fensterfunktionen entsprechend

abgefangen. Wechselnde Schwingungsrichtungen im Bild können jedoch nicht erfasst werden, weshalb eine Zerlegung in kleinere, in sich gleichgerichtete Kacheln zur Ableitung der Schwingungsrichtung unumgänglich ist (Bruck und Lehner 2013). Die Unendlichkeit periodischer Funktionen wird in der Wavelet-Theorie so umgangen, dass jede Schwingung mit zunehmendem Abstand vom Zentrum an Einfluss verliert, also abschwingt. Der einfachste Vertreter aus der Familie der »Lets« ist das Haar-Wavelet als Differenz zweier Summen beispielsweise entlang der zeitlichen Dimension (Schollerer et al. 2022). Fourier und Wavelets sind im Eindimensionalen definiert und können auf zwei unabhängige Dimensionen theoretisch problemlos übertragen werden. Praktisch sind die beiden Dimensionen jedoch nicht unabhängig, d.h. vertikale, horizontale und diagonale Kanten können gut erfasst werden, da diese nur jeweils eine Dimension bzw. beide in gleichem Maße betreffen (Schmitt 2012). Schräg verlaufende Kanten müssen wieder aus der Kombination beider Richtungen zusammengesetzt werden, was sie anfällig für Rauschen macht.

Diese Einschränkung kann man umgehen, indem man die Basisfunktion statt im eindimensionalen direkt im zwei- oder mehrdimensionalen Raum definiert. So entstanden die Curvelets. Bei diesem Ansatz wird das komplette Bild nach linearen, Ridgelet (»kleine Kante«) genannten Strukturen abgetastet, welche aufgrund des festgeschriebenen Verhältnisses von Länge zu Breite kurvenähnlich ausschauen. Die Curvelets sind sowohl multiskalig als auch multidirektional, d.h. sie zeichnen jede beliebige Richtung im Bild bestmöglich nach (Candès et al. 2006), was für den gewünschten Anwendungsfall Voraussetzung ist. Auch inhärentes Bildrauschen stellt durch die über die multiskalige Betrachtung eingeführte Glättung entlang von Kanten kein Problem dar (Schmitt et al. 2014). Durch den Einfluss mehrerer benachbarter Curvelets auf den Wert des gleichen Pixels ist jedoch die pixelweise Richtungsbestimmung nicht eindeutig möglich. Diesen Nachteil gleichen die Schmittlets aus, indem sie jedem Pixel ein dominantes Schmittlet mit einer fest definierten Form, Größe und Orientierung zuweisen (Schmitt 2016). Die ursprüngliche Anwendung der Schmittlets war die Verbesserung und Analyse von Radarbildern, die durch den Speckle-Effekt stark verrauscht sind. Wie die Curvelets schmiegen sich die Schmittlets bestmöglich den im Bild vorhandenen Strukturen an und glätten homogene Bereiche weitestgehend, während Kanten perfekt erhalten bleiben. Da die Glättung im Vordergrund steht, werden in der ersten Veröffentlichung Ableitungs- und Krümmungsfunktionen nur angedacht, aber noch nicht praktisch umgesetzt (Schmitt 2016). Diese methodische Lücke wird nun mit der vorliegenden Studie geschlossen: aus Binomialkoeffizienten wird ein den Schmittlets ähnlicher Glättungsfilter namens »SmoothSlet« generiert, welcher nach Ableitung in Querrichtung zum »DiffSlet« wird, um Kanten nachzuzeichnen, und nach nochmaliger Ableitung in Querrichtung zum »CurvedSlet«, um Streifen einer gewissen Breite im Bild unmittelbar zu erfassen.

3 Methodik

Die Methodik zur Ableitung der Bewirtschaftungsrichtung gestaltet sich dreistufig: Zuerst werden die Spektralkanäle zu einem aussagekräftigen Kanal fusioniert, anschließend findet die Slet-Analyse mit SmoothSlets, DiffSlets und CurvedSlets statt, um abschließend die erkannten Richtungen auf Feldstücksebene zusammenzufassen.

3.1 Spektrale Fusion

Die spektralen Kanäle im sichtbaren Bereich sind in aller Regel stark korreliert. Somit bringt es keinen Mehrwert, die Kanäle einzeln zu betrachten, sondern es ist viel effektiver, die Kanäle spektral zu einem aussagekräftigen Kanal zu fusionieren (Zangl et al. 2022). Dieser Schritt vereinfacht zusätzlich die Slet-Analyse, da nur noch ein Kanal zerlegt werden muss statt der vier im RGB- und CIR-Bild enthaltenen Eingangskanäle Blau, Grün, Rot und (Nahes) Infrarot. Da die Slet-Zerlegung auf dem Kontrast zwischen Fahr- bzw. Reifenspur und der Umgebung aufbaut, wurde dieser Kontrast vorab mit Hilfe des Fisher-Kriteriums (Wurm et al. 2016) für verschiedene Fusionsansätze eva-

3.2 SmoothSlets, DiffSlets und CurvedSlets

Die Slet-Theorie basiert auf dem hyperbolischen Tangens als Verteilungsfunktion. Die erste Ableitung kann folglich wie ein Glättungsfilter ähnlich der Gaußschen Glockenkurve eingesetzt werden (Schmitt et al. 2015). SmoothSlets sind ursprünglich darauf ausgelegt, homogene Flächen, die nur Rauschen aufweisen, zu glätten, aber Kanten perfekt zu erhalten (Schmitt 2016). In dieser Studie wird die Urform der Slets als SmoothSlet bezeichnet, um den Glättungsaspekt hervorzuheben. Wenn Kanten nicht nur erhalten, sondern gezielt herausgefiltert werden sollen, empfiehlt sich die zweite Ableitung: DiffSlets, die ähnlich einem Sobel-Operator den Gradienten wiedergeben. Im Gegensatz zum Sobel-Operator findet bei den DiffSlets zeitgleich – analog zu den Curvelets – eine Glättung entlang der Kante statt. Dank ihrer langgezogenen Form kann nun auch die Winkelabstastung enorm verfeinert werden (Candès et al. 2006). Zur Extraktion von Streifen einer gewissen Breite (Übergang hell-dunkel-hell oder dunkel-hell-dunkel) bietet sich die dritte Ableitung des Tangens Hyperbolicus an: CurvedSlets. Alle drei Varianten sind in Abb. 3 im Eindimensionalen als kontinuierliche Funktion sowie als diskrete Approximation dargestellt.

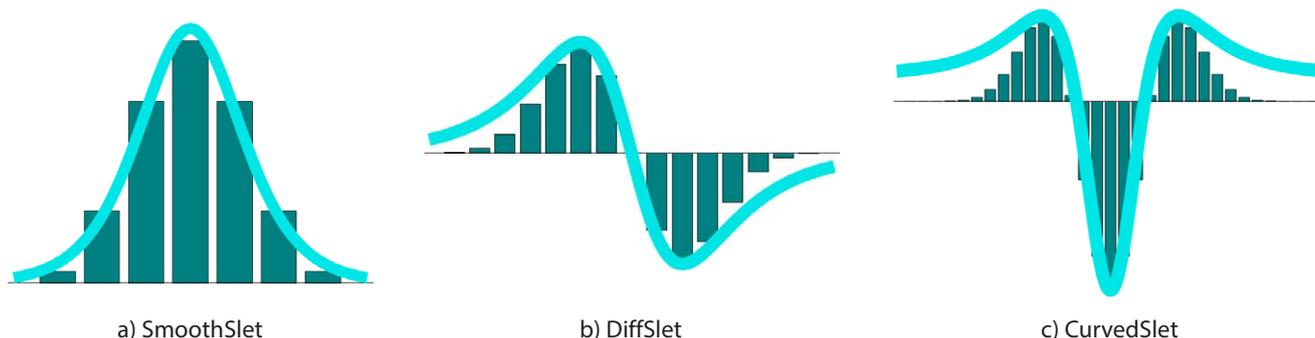


Abb. 3: Querschnitte der Slets von links nach rechts: »SmoothSlet« (1. Ableitung des TANH), »DiffSlet« (2. Ableitung des TANH), »CurvedSlet« (3. Ableitung des TANH) mit jeweiliger Approximation durch die Binomialverteilung im Pascalschen Dreieck.

liert. Im Einzelnen sind dies der panchromatische Kanal (PAN) als Summe über die sichtbaren Wellenlängen, der Normalized Difference Vegetation Index (NDVI) als Kombination aus sichtbarem Rot und nahem Infrarot sowie die optischen Kennaugh-Elemente als orthogonale, normalisierte Transformation des Spektralraums (Schmitt und Wendleder 2018). Die Ergebnisse aus der Voranalyse sowie praktische Erwägungen heben PAN und NDVI als aussichtsreichste Kanalkombinationen hervor. Sie liefern einen vergleichbar hohen Kontrast, wobei NDVI speziell auf gesunde Vegetation gegenüber offenem Boden (in der Reifenspur) anspricht und PAN eher Hell-Dunkel-Unterschiede hervorhebt (Aigner 2021). Für die zukünftige Anwendung hätte PAN zusätzlich den Vorteil, dass er mit jedem handelsüblichen UAV ebenso flächendeckend aufgenommen werden kann, während der NDVI einen Infrarot-Kanal und damit teurere und schwerere Sensorik erfordert, die nicht auf jedem handelsüblichen UAV verbaut ist.

Zur einfacheren Implementierung wurde statt der kontinuierlichen Funktionsdefinition eine diskrete Approximation mit Hilfe des Pascalschen Dreiecks gewählt. Dieses liefert die Binomialkoeffizienten, welche wie ein Glättungsfilter (SmoothSlet) angewendet werden können. Deren diskrete Ableitung ergibt den Kantenfilter (DiffSlet). Die nächste Ableitung liefert den Krümmungsfilter (CurvedSlet). Wie in Abb. 3 zu sehen, weichen die kontinuierlichen Funktionen und ihre diskreten Implementierungen nur minimal voneinander ab. Lediglich bei den CurvedSlets fällt die Approximation nach links und rechts schneller ab als die kontinuierliche Funktion. Dies ist in Anbetracht der konkreten Anwendung jedoch eher als Vorteil zu werten, da schmale parallel verlaufende Streifen wie die Reifenspuren exakter erfasst werden, siehe Abb. 4.

Anhand der typischen Länge und Breite von Fahrspuren im DOP20 kann nun das passende Slet designt werden. Längs der Fahrspur erfolgt gemäß Abb. 4 eine großzügige

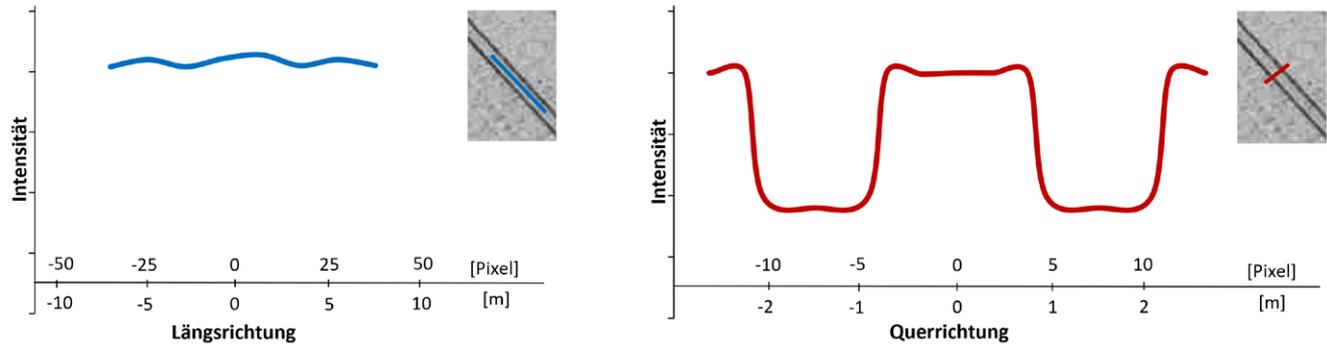


Abb. 4: Typischer Grauwertverlauf längs und quer zur Fahrspur. Während in Längsrichtung – abgesehen vom Rauschen – durchweg gleich hohe Grauwerte zu verzeichnen sind, bewirkt die Reifenspur starke Kontraste im Querprofil entlang Streifen ähnlicher Breite und mit ähnlichem Abstand.

Glättung über 71 Pixel (14 m), um Rauschen bestmöglich zu eliminieren.

Quer zur Fahrspur stehen die in Abb. 3 illustrierten Slet-Querschnitte zur Auswahl:

- **SmoothSlets**, die homogene Bereiche entlang der Fahrspur erkennen, indem sie das geglättete Bild mit dem Originalbild abgleichen. Das Slet mit der geringsten Abweichung passt am besten. Die ermittelte Breite beträgt 7 Pixel, was 140 cm entspricht.
- **DiffSlets**, die den Übergang zwischen dunkler Reifenspur und heller Umgebung erkennen. Der maximale Kontrast liefert das lokal am besten passende DiffSlet. Die Breite beträgt 15 Pixel, d. h. je 7 Pixel im Hellen und 7 Pixel im Dunklen mit einem Nulldurchgang im Zentrum, das als wahrscheinliches Mischpixel besser ausgespart wird.
- **CurvedSlets**, die die Krümmung quer zur Fahrspur erkennen. Der maximale Kontrast liefert das optimale CurvedSlet. Die Breite beträgt 21 Pixel, was der Kombination 7 Pixel hell, 7 Pixel dunkel und wieder 7 Pixel hell oder umgekehrt entspricht.

Bei DiffSlets und CurvedSlets spielt prinzipiell die Reihenfolge der Grauwerte eine Rolle. Eine umgekehrte Reihenfolge bewirkt auch ein umgekehrtes Vorzeichen. Da jedoch

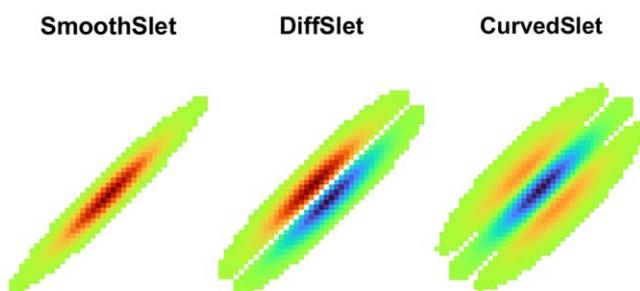


Abb. 5: Flächenhafte Darstellung der Slets: SmoothSlet, DiffSlet und CurvedSlet beispielhaft in der Ausrichtung 45°, positive Werte in Rot und negative Werte in Blau (vgl. Abb. 3). Die Drehung der Filtermasken erfolgt in 5°-Schritten zwischen 0° und 180° in der aktuellen Implementierung.

die maximale Abweichung von Null unabhängig vom Vorzeichen betrachtet wird, ist es unerheblich, ob nun die Abfolge hell-dunkel-hell oder dunkel-hell-dunkel betrachtet wird.

Die einzelnen Slets unterscheiden sich dann nur noch in ihrer Ausrichtung. Die ursprünglich auf Nord-Süd-verlaufende Fahrspuren angepasste Filtermaske wird in 5°-Schritten gedreht (Abb. 5), um auch schräg verlaufende Fahrspuren bestmöglich zu erfassen. Eine feinere Abtastung (z. B. in 1°-Schritten) ist durchaus umsetzbar, aber bezüglich der beabsichtigten Anwendung gar nicht nötig. Aktuell wird in der Beurteilung der Flächen lediglich nach Quer- oder Längsbewirtschaftung unterschieden, weshalb die Abtastung in 36 Stufen (das entspricht 18 Stufen zwischen »längs« und »quer«) nach Nyquist-Shannon-Theorem weit mehr als ausreichend ist. Die Richtung des lokal am besten zum Bild passenden Slets wird festgehalten. Das Ergebnis der Slet-Analyse ist somit ein Bild in Originalauflösung mit einer Richtungsangabe pro Pixel.

3.3 Aggregation auf Feldstücksebene

Verständlicherweise liefern die Slet-Algorithmen ausschließlich die lokale Ausrichtung der Fahrspur gemäß DOP20. Das Vorgewende zeichnet sich beispielsweise durch einen kontinuierlichen Wechsel der Slet-Richtung entlang der Fahrspur ab. Da die Modellierung des P-Faktors jedoch die über das gesamte Feldstück vorherrschende Bewirtschaftungsrichtung verlangt und diese auch meist einheitlich ist, wird für jedes Feldstück die am häufigsten vorkommende Slet-Richtung ermittelt. Das Vorgewende fällt somit automatisch heraus. Auf Basis dieser Feldstückspolygone wird anschließend auch die Validierung der Ergebnisse durchgeführt. Wiesen werden aufgrund bekannter Nutzungsart und somit der darin nicht vorhandenen Bewirtschaftungsrichtung vorab aussortiert.

4 Ergebnisse und Validierung

Die Pilotstudie umfasst drei für Niederbayern repräsentative Untersuchungsgebiete, in denen unterschiedliche Formen von Landwirtschaft betrieben werden:

Durch die gute Bodenbeschaffenheit ist die Region des **Dungaus** (Abb. 6) mit ca. 80 bis 90 % Ackerbau überwiegend landwirtschaftlich geprägt. Es gibt kaum forstwirtschaftliche Nutzung. Außerdem liegen hier vergleichsweise großflächige Flure vor, welche nur spärlich durch Strukturen wie Hecken, Gräben oder Alleen durchzogen oder begrenzt werden (LfU 2011, Nr. 33).

Der Hügellandcharakter mit breiten Tälern ist in der Kulturlandschaft des **Isar-Inn-Hügellands** (Abb. 7) vorherrschend. Hauptsächlich wird Ackerbau betrieben sowie Grünland genutzt. Die Forstwirtschaft ist im bayernweiten Vergleich eher unterdurchschnittlich vertreten (LfU 2011, Nr. 32).

Im **Inneren Bayerischen Wald** (Abb. 8) findet sich gegenteilig zu den anderen Untersuchungsgebieten weniger Ackerbau, hingegen überwiegt in den mittleren und höheren Lagen hauptsächlich Waldlandschaft. In den mittleren Lagen ist als landwirtschaftliche Nutzung vorwiegend Grünland vertreten, in tieferen Lagen teilweise Ackerbau (LfU 2011, Nr. 30).

Die Orientierung des pro Pixel am besten passenden DiffSlets wird in Abb. 6, Abb. 7 und Abb. 8 jeweils links mit Hilfe einer Farbkodierung visualisiert. Die Aggregation auf Feldstückebene wird rechts, bei größeren Feldstücken mit Angabe der Orientierung als Zahlenwert angezeigt. Offenbar konnte für jedes Feldstück die Bewirtschaftungsrichtung eindeutig bestimmt werden. Die Ergebnisse der SmoothSlets und CurvedSlets werden der Übersichtlichkeit halber nur bezüglich ihrer Genauigkeit numerisch in Tab. 3 aufgeführt.

Da für die großflächige – beispielsweise bayernweite – Anwendung auch der Rechenaufwand von berechtigtem Interesse ist, werden in Tab. 2 die Rechenzeiten für die Slet-basierte Richtungsanalyse auf einem Standard-PC angegeben. Diese beziehen sich auf die aktuelle Implementierung mit einer Winkelabtastung von 5° und den oben angegebenen Filtergrößen.

Um die Qualität der Ergebnisse beurteilen zu können, werden stichprobenartig Richtungswinkel anhand visueller Orthophotointerpretation manuell gemessen und die

Tab. 2: Rechenzeiten der Slet-Analyse pro Testgebiet und durchschnittlich pro Quadratkilometer auf Standardrechner: x-64 basierter PC, Prozessor: 2,20 GHz mit 44 logischen Prozessoren, Datenspeicher (RAM): 128 GB

Gebiet	SmoothSlets	DiffSlets	CurvedSlets
1	16–28 s	9–12 s	11–12 s
2	7–12 s	5–6 s	7–8 s
3	8–20 s	6–10 s	9–12 s
Ø pro km ²	46 s	29 s	37 s

absolute Abweichungen der automatisch abgeleiteten Bewirtschaftungsrichtung berechnet. Die Ergebnisse für alle Testgebiete und beide Eingangskanäle (PAN, NDVI) sind in Tab. 3 gelistet. Dort wird jeweils der Anteil an Messungen angegeben, der eine maximale Abweichung von 5° bzw. 10° nicht übersteigt. Die Abweichungen werden auch in Abb. 9 am Beispiel des Dungaus und in Abb. 10 am Beispiel des Isar-Inn-Hügellands nach Eingangskanälen PAN und NDVI getrennt visualisiert. Zusätzlich enthalten diese Karten auch noch eine Klassifikation nach visueller Erkennbarkeit der Bewirtschaftungsrichtung, die selbst bei erfahrenen Luftbildinterpreten nicht in allen Fällen ohne Weiteres gegeben ist.

5 Diskussion

Die Genauigkeitsanalyse in Tab. 3 liefert ein sehr differenziertes Bild der erkannten Bewirtschaftungsrichtungen. Die geringsten Genauigkeitswerte sind im Inneren Bayerischen Wald zu verzeichnen mit lediglich 33 % der Abweichungen unter 5°, aber immerhin 76 % unter 10° bei Einsatz der Smooth-Slets. Die höchsten Genauigkeiten liefern die DiffSlets für das Isar-Inn-Hügelland mit 89 % unter 5° und 100 % unter 10°, wobei die SmoothSlets im Dungau ähnlich gute Ergebnisse erzielen. Die CurvedSlets führen – im offenbar für alle drei Algorithmen anspruchsvollen Testgebiet Innerer Bayerischer Wald – mit 67 % unter 5° und 90 % unter 10° zu den besten Ergebnissen.

Die Grenzwerte von 5° und 10° wurden bewusst gewählt, da es sich bei 5° um die Winkelabtastung und bei 10° laut Nyquist-Shannon-Theorem um den kleinsten bei dieser Abtastung überhaupt unterscheidbaren Winkel handelt. Daher ist es beachtlich, dass im PAN-Kanal durchschnittlich 95 % der Bewirtschaftungsrichtungen mit weniger als 10° Abweichung bestimmt werden können und somit die theoretisch zu erwartende Genauigkeit erreicht ist. Trotzdem bestehen große Unterschiede zwischen den Untersuchungsgebieten und den drei Verfahren, die vermutlich auf die Situation vor Ort zurückzuführen sind. Die Karten in Abb. 9 und Abb. 10 versuchen dies zu illustrieren.

Pro Untersuchungsgebiet werden zur Validierung landwirtschaftliche Flächen mit unterschiedlichen Charakteristiken ausgewählt. Eine visuelle Interpretation der Orthophotos stuft die Feldstücke bezüglich der visuellen Erkennbarkeit ihrer Bewirtschaftungsrichtung bzw. des Kontrasts zwischen Fahrgasse und Feldfrucht in die Kategorien schlecht, gut und sehr gut ein. Bezüglich dieser Qualitätsklassen kann jedoch keine grundsätzliche Regelmäßigkeit in den Abweichungen erkannt werden. Einzelne Ausreißer kommen sowohl auf visuell schlecht (Abb. 9 NDVI) als auch auf gut (Abb. 9 PAN) einzuschätzenden Feldstücken vor. Es wäre daher wünschenswert, wenn die Slet-Analyse selbst oder die anschließende Aggregation auf Feldstückebene zukünftig ein Qualitätsmaß mitliefern würde, mit dessen Hilfe die Zuverlässigkeit der abgeleiteten

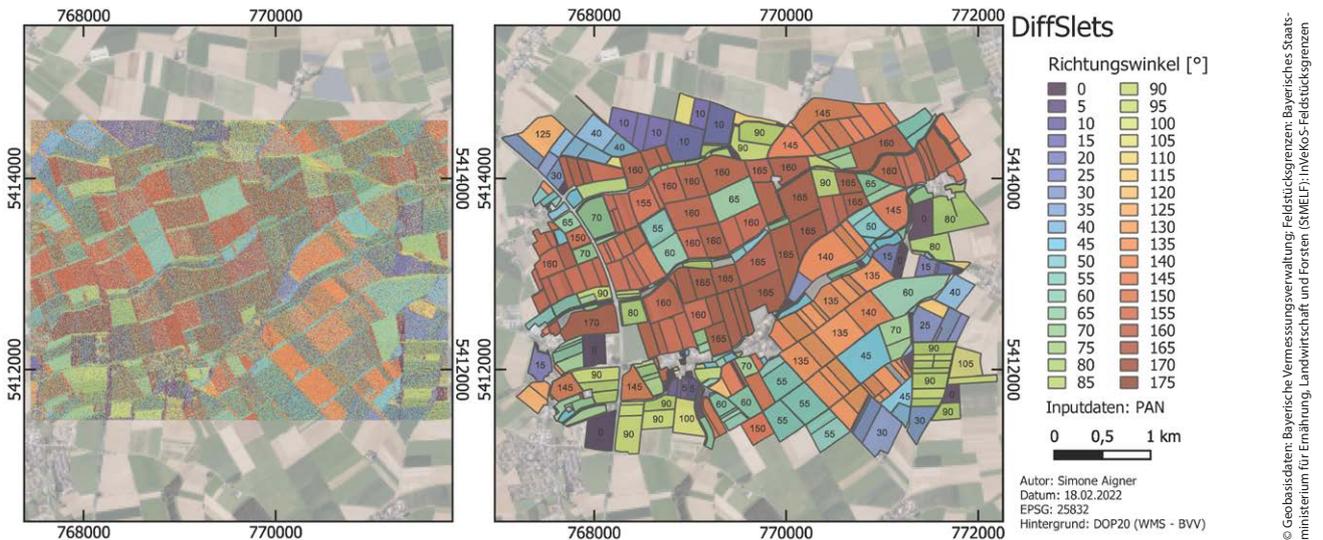


Abb. 6: Lokal vorherrschende Richtung aus der DiffSlet-Analyse auf Basis des PAN-Kanals (links) und Aggregation auf Feldstücksebene (rechts) für das Untersuchungsgebiet Dungau

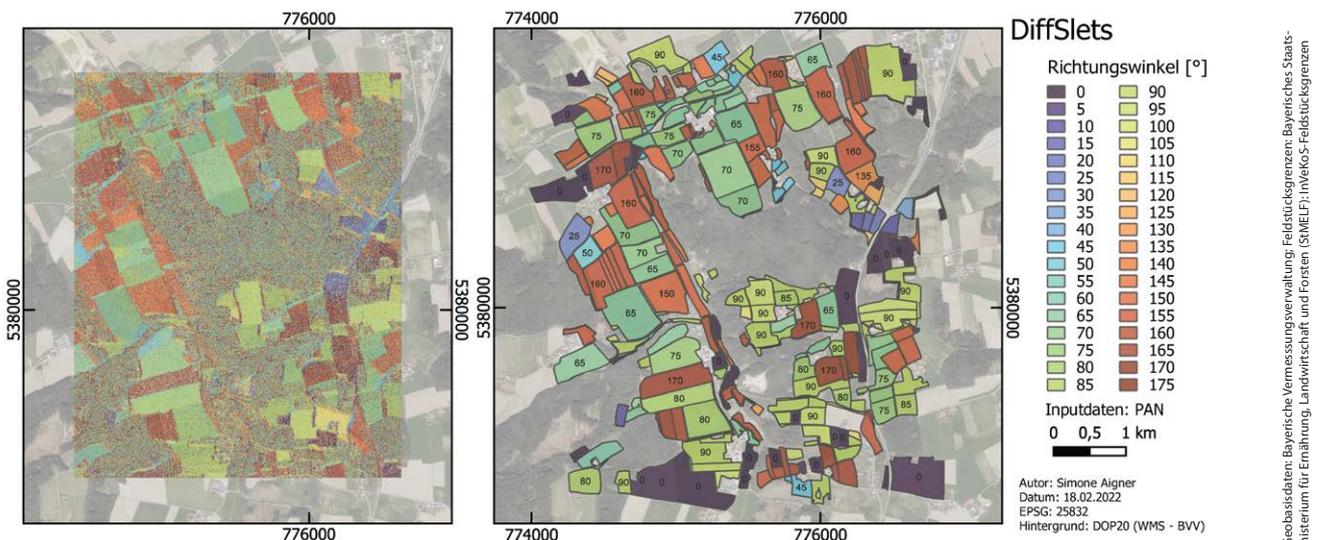


Abb. 7: Lokal vorherrschende Richtung aus der DiffSlet-Analyse auf Basis des PAN-Kanals (links) und Aggregation auf Feldstücksebene (rechts) für das Untersuchungsgebiet Isar-Inn-Hügelland.

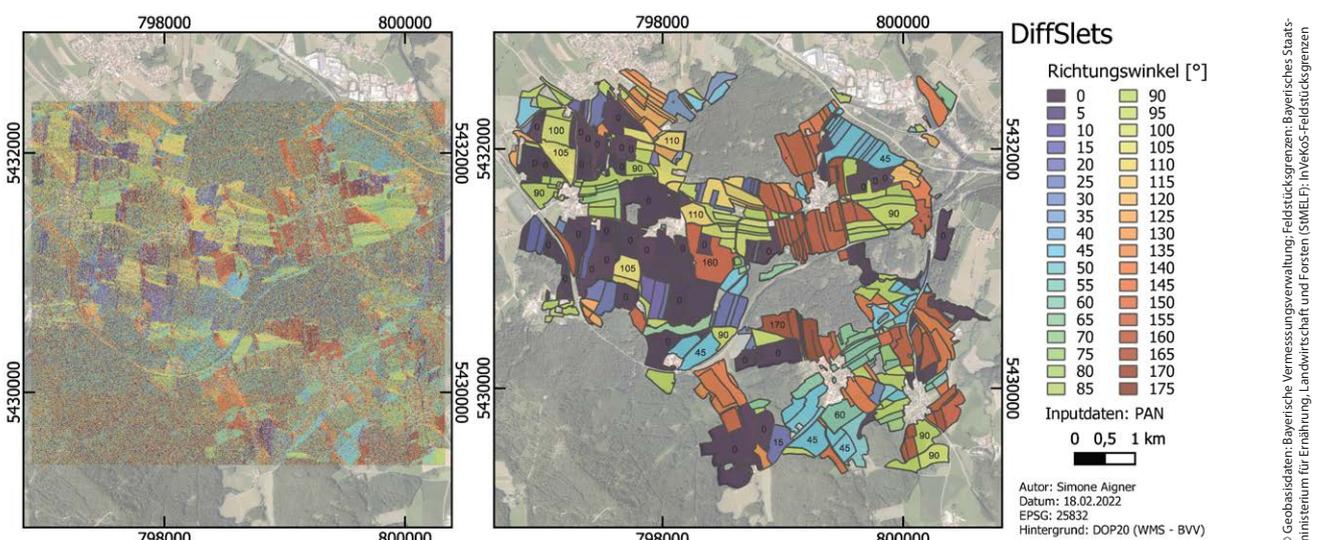


Abb. 8: Lokal vorherrschende Richtung aus der DiffSlet-Analyse auf Basis des PAN-Kanals (links) und Aggregation auf Feldstücksebene (rechts) für das Untersuchungsgebiet Innerer Bayerischer Wald.

© Geobasisdaten: Bayerische Vermessungsverwaltung; Feldstücksgrenzen: Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten (SMELF); inVekoS-Feldstücksgrenzen

© Geobasisdaten: Bayerische Vermessungsverwaltung; Feldstücksgrenzen: Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten (SMELF); inVekoS-Feldstücksgrenzen

© Geobasisdaten: Bayerische Vermessungsverwaltung; Feldstücksgrenzen: Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten (SMELF); inVekoS-Feldstücksgrenzen

Tab. 3: Genauigkeit der automatisch erkannten Bewirtschaftungsrichtung pro Feldstück, angegeben als Anteil [in Prozent] an Messungen mit einer Abweichung von weniger als 5° bzw. 10° für alle drei Testgebiete (inklusive Durchschnitt) und beide Eingangskanäle PAN und NDVI.

Gebiet	SmootSlet		DiffSlet		CurvedSlet		Kanal
	< 5°	< 10°	< 5°	< 10°	< 5°	< 10°	
1	88	100	86	98	86	100	NDVI
	81	95	81	98	57	74	PAN
2	89	96	89	100	81	100	NDVI
	81	93	89	100	37	52	PAN
3	43	86	67	86	67	90	NDVI
	33	76	48	81	57	71	PAN
Ø	73	94	81	95	78	97	NDVI
	65	88	73	93	50	65	PAN
≤	5°	10°	5°	10°	5°	10°	%

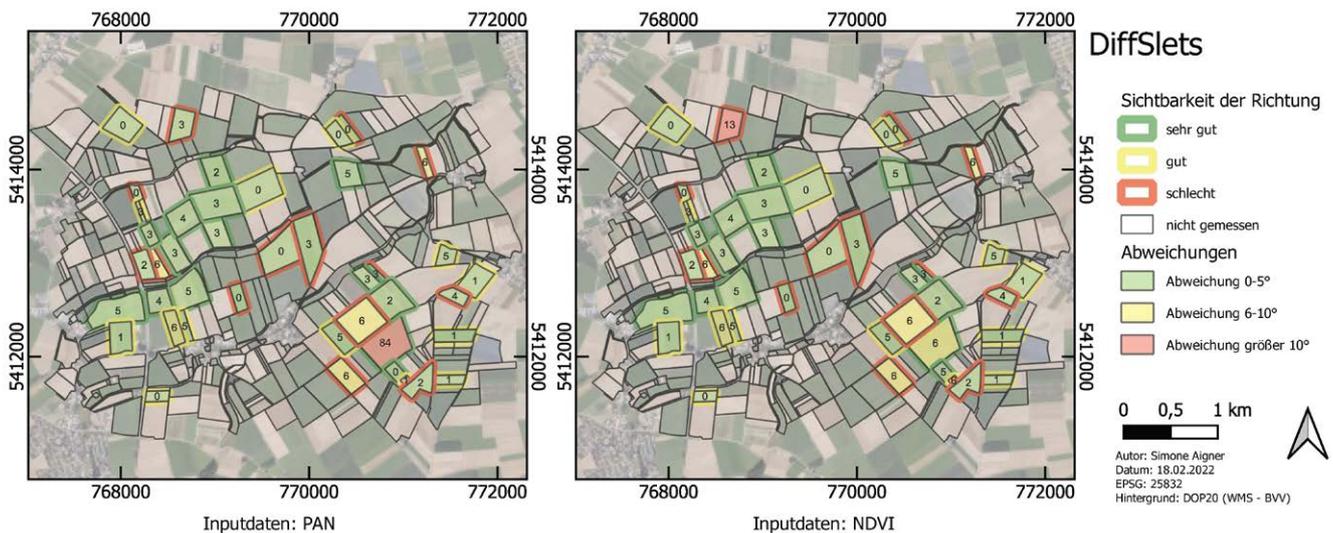


Abb. 9: Kartierung der Richtungsabweichungen (eingefärbte Fläche mit Zahlenwert) der DiffSlet-Analyse im Dungau. Die farbige Umrandung gibt an, wie gut die Bewirtschaftungsrichtung rein visuell von einem Luftbildinterpret zu erkennen war.

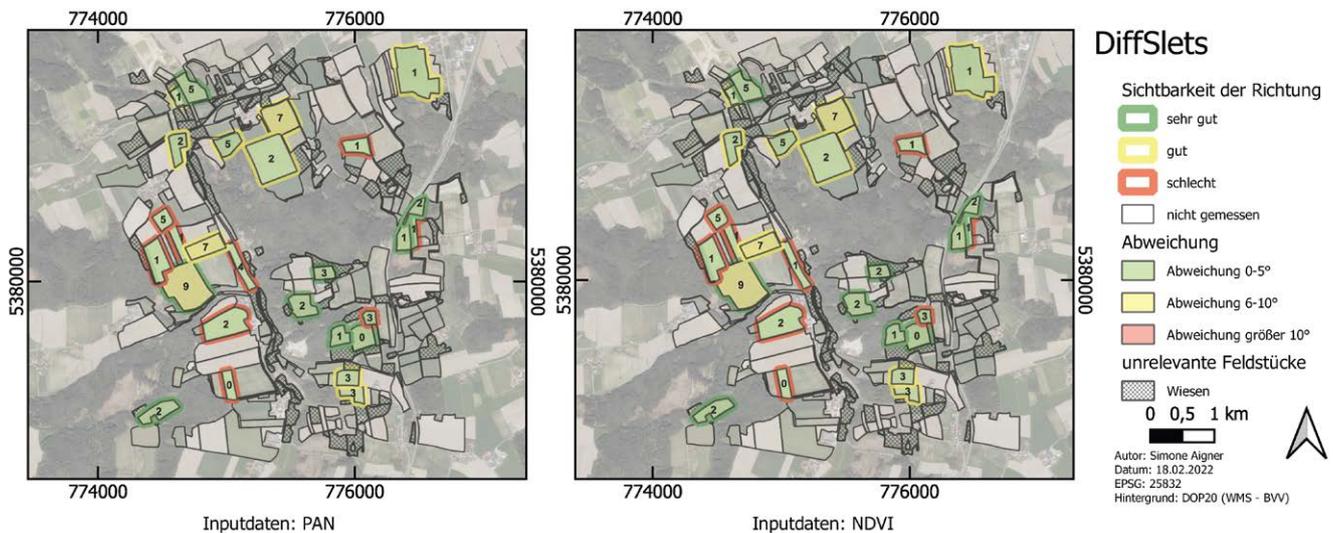


Abb. 10: Kartierung der Richtungsabweichungen (eingefärbte Fläche mit Zahlenwert) der DiffSlet-Analyse im Isar-Inn-Hügelland. Die farbige Umrandung gibt an, wie gut die Bewirtschaftungsrichtung rein visuell von einem Luftbildinterpret zu erkennen war.

© Geobasisdaten: Bayerische Vermessungsverwaltung; Feldstücksgrenzen: Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten (SMELF); inVeKoS-Feldstücksgrenzen

© Geobasisdaten: Bayerische Vermessungsverwaltung; Feldstücksgrenzen: Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten (SMELF); inVeKoS-Feldstücksgrenzen

Bewirtschaftungsrichtung geschätzt werden kann, um – falls nötig – einzelne Feldstücke gezielt visuell zu überprüfen. Momentan wird nur der Modus der Verteilung pro Feldstück ausgegeben. Als Qualitätsmaß könnte hier beispielsweise die Dominanz des Modus, die Homogenität der Verteilung (Schmitt et al. 2023) oder ganz klassisch die Standardabweichung der pro Feldstück erkannten Orientierungen angegeben werden.

Bereits beim Vergleich der Eingangsdaten fällt als mögliche Herausforderung die Darstellung von brachliegenden oder frisch eingesäten Feldern ohne Vegetation mit dem NDVI als Eingangskanal auf, da ohne Vegetation das Nahe Infrarot nur schwach reflektiert wird und die Felder somit schwarz dargestellt werden. Folglich können im NDVI keine Fahrgassen, welche die Bewirtschaftungsrichtung anzeigen würden, detektiert werden. Dies deutet auf eine bessere Eignung der PAN-Kombination hin, auch wenn bei dichter Vegetation der NDVI minimal besser abschneidet (vgl. Abb. 9).

PAN hätte, wie schon eingangs erwähnt, zusätzlich den Vorteil, dass er mit jeder handelsüblichen UAV-Kamera aufgenommen werden kann. Wenn keine aktuellen Orthophotos zur Verfügung stehen, wäre folglich auch eine UAV-Befliegung ohne größeren Aufwand möglich.

Je nach Untersuchungsgebiet schneidet die eine oder andere Methodik minimal besser ab, wobei die übrigen Ansätze meistens mit wenig Abstand aufschließen. Somit

stellen sich im Durchschnitt die DiffSlets in allen drei Gebieten als sehr gut geeignete Methode zur Detektion der Bewirtschaftungsrichtung heraus. Durch die zugrunde liegende Filtermaske, welche Fahrspuren als abrupte Intensitätsänderungen quer zu langgezogenen Kanten detektiert, kann auch bei variierender Breite der Fahrspuren von einer stabilen Anwendung der Methodik ausgegangen werden. Nachdem die DiffSlets auch die geringste Rechenzeit aufweisen, spricht dies ebenfalls für eine Anwendung dieser Kernel-Sammlung. Zukünftige Weiterentwicklungen der Methodik könnten multi-skalige DiffSlets einführen, um die Kantendetektion bei geringem Kontrast oder hohem Bildrauschen zu stabilisieren.

Ziel dieser Studie ist die vollautomatische Ableitung der Bewirtschaftungsrichtung aus dem Digitalen Orthophotomosaik. Dennoch soll abschließend ein Ausblick gegeben werden, welchen Mehrwert die gewonnene Information für die lokale Anpassung des P-Faktors hat. Dafür wird in Abb. 11 die Bewirtschaftungsrichtung, die prozentuale Hangneigung, die Exposition sowie exemplarisch die Hanglänge kartiert. Zusätzlich wird der Winkel zwischen hangparalleler und tatsächlicher Bewirtschaftung als Zahl und farbig hinterlegte Fläche angezeigt.

Derartige Karten könnten in naher Zukunft flächendeckend zur Verfügung gestellt werden, um zum einen auf eine feiner aufgelöste Abschätzung der Quer-/Nichtquerbewirtschaftung einzugehen und daraus schließlich auch

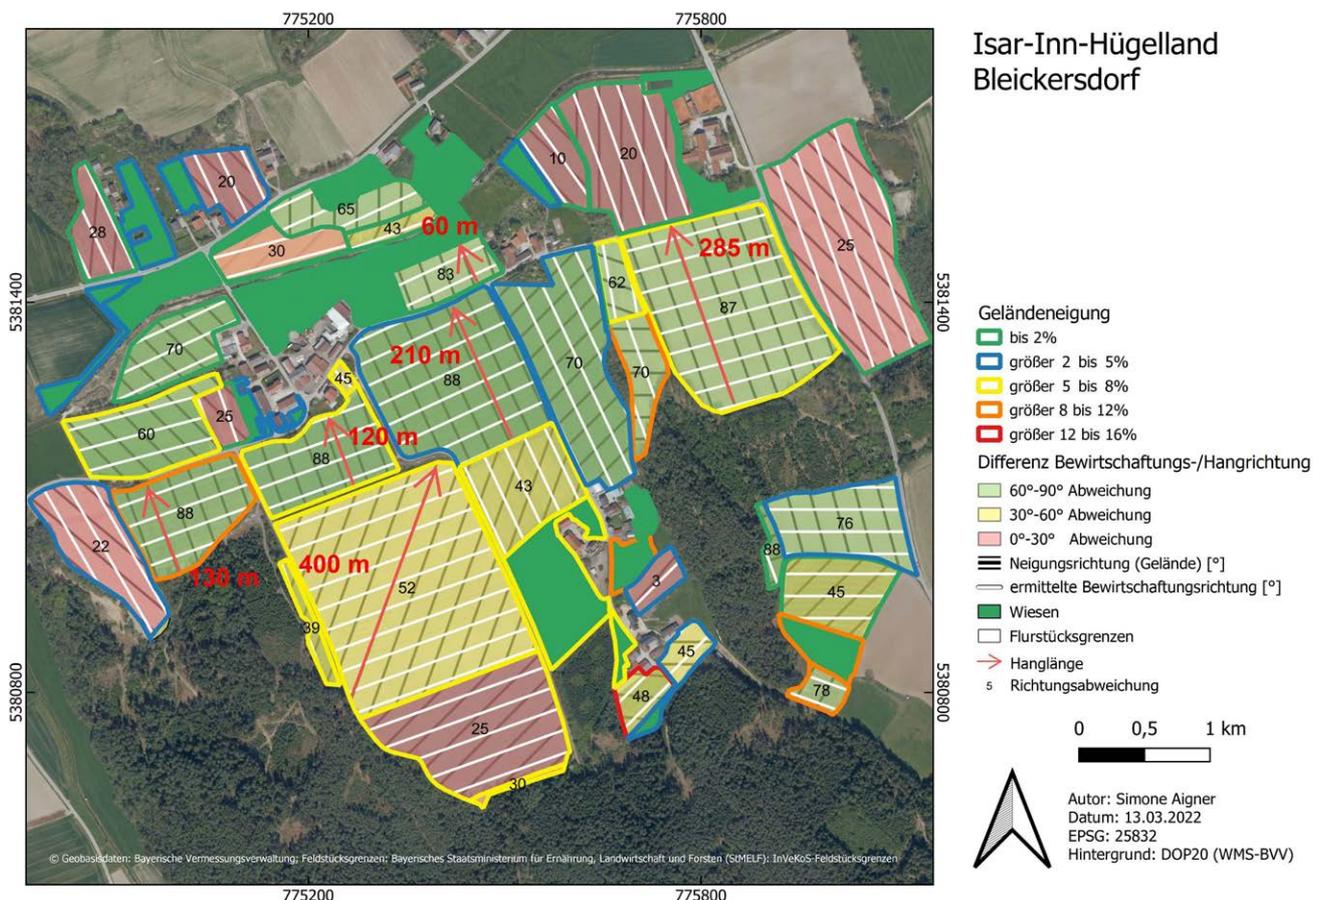


Abb. 11: Karte mit Bewirtschaftungsrichtung, Hangneigung und -exposition sowie Hanglänge als Eingangsparameter für die Berechnung des P-Faktors. Der Winkel zwischen hangparalleler und aktueller Bewirtschaftungsrichtung ist als Zahl angegeben.

bayernweit eine Neubestimmung des P-Faktors – nicht einheitlich, sondern jeweils lokal an die tatsächliche Situation anpasst – voranzutreiben. Dadurch ist eine weitere signifikante Verbesserung der im Erosionsatlas Bayern bereitgestellten Modellierung zu erwarten.

6 Fazit

Die automatische Bestimmung der Bewirtschaftungsrichtung aus dem Digitalen Orthophoto ist zuverlässig möglich. Am besten eignet sich dafür der panchromatische Kanal, der sich als Summe aus den Spektralkanälen im sichtbaren Bereich zusammensetzt und mit jeder handelsüblichen Kamera – wie auf UAVs typischerweise montiert – aufgenommen werden kann. Methodisch hat sich der DiffSlet-Ansatz als schnellster und genauester Ansatz herausgestellt, wenn auch im Einzelfall SmoothSlets oder CurvedSlets durchaus vergleichbare Ergebnisse liefern. Die beobachteten Richtungsabweichungen liegen durchschnittlich bei 81 % der Feldstücke unter 5° und bei 95 % der Feldstücke unter 10°, was bei der implementierten Richtungsabtastung von 5° als ausgezeichnet angesehen werden kann. Von kleineren methodischen Raffinessen wie der Einführung eines Zuverlässigkeitsmaßes oder multi-skaliger Filtermasken abgesehen, ist der in dieser Pilotstudie entwickelte Prozessor bereits jetzt großflächig mit überschaubarem Aufwand einsetzbar.

Danksagung

Die Autoren möchten sich bei der Bayerischen Vermessungsverwaltung für die kostenlose Bereitstellung der Orthophotos (DOP20) und der Geländehöhen, bei der Bayerischen Landesanstalt für Landwirtschaft für die Bereitstellung der Feldstücksdaten sowie beim Amt für Ländliche Entwicklung Niederbayern für die Unterstützung bei der Vorbereitung dieser Studie recht herzlich bedanken.

Literatur

- Aigner, S. (2021): Musterbasierte Bildanalyse der Bewirtschaftungsrichtung landwirtschaftlicher Flächen. Bachelorarbeit, Fakultät für Geoinformation, Hochschule München.
- Bayerische Landesanstalt für Landwirtschaft [LfL] (2019): Bodenerosion – Die Allgemeine Bodenabtragsgleichung – ABAG – Hilfsmittel und Handlungsempfehlung. In: LfL Information, 5. www.lfl.bayern.de/mam/cms07/publikationen/daten/informationen/bodenerosion-lfl-information.pdf, letzter Zugriff 3/2023.
- Bayerische Landesanstalt für Landwirtschaft [LfL] (2022): Erosionsatlas Bayern – Karten zur Erosionsgefährdung von Ackerflächen. www.lfl.bayern.de/iab/boden/029288/, letzter Zugriff 3/2023.
- Bayerisches Landesamt für Umwelt [LfU] (2011): Entwurf einer kulturlandschaftlichen Gliederung Bayerns als Beitrag zur Biodiversität – Nr. 30/32/33. www.lfu.bayern.de/natur/kulturlandschaft/gliederung/index.htm, letzter Zugriff 3/2023.
- Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten [StMELF] (2005): Ländliche Entwicklung in Bayern. Informationskompendium. www.lwf.bayern.de/mam/cms01/landentwicklung/dokumentationen/dateien/le_infokompendium.pdf, letzter Zugriff 3/2023.
- Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten [StMELF] (2022): Landwirtschaftliche Flächennutzung. www.agrarbericht.bayern.de/landwirtschaft/landwirtschaftliche-flaechennutzung.html, letzter Zugriff 3/2023.
- Bruck, M., Lehner, S. (2013): Coastal wave field extraction using TerraSAR-X data. In: Journal of Applied Remote Sensing, Vol. 7, Issue 1, Number 073694. DOI: 10.1117/1.JRS.7.073694, letzter Zugriff 3/2023.
- Candès, E., Demanet, L., Donoho, D., Ying, L. (2006): Fast Discrete Curvelet Transforms. In: SIAM Journal on Multiscale Modeling and Simulation, Vol. 5, Issue 3. DOI: 10.1137/05064182X, letzter Zugriff 3/2023.
- Candès, E., Donoho, D. (1999): Curvelets – A Surprisingly Effective Nonadaptive Representation For Objects with Edges. In: Stanford Digital Repository. Technical Report No. GEN_1999-28. <https://purl.stanford.edu/hw450gp6206>, letzter Zugriff 3/2023.
- Haralick, R., Shanmugam, K., Dinstein, I. (1973): Textural features for image classification. In: IEEE Transactions on Systems, Man, and Cybernetics, Vol. 3, Issue 6, 610–621. DOI: 10.1109/TSMC.1973.4309314, letzter Zugriff 3/2023.
- Hessisches Landesamt für Naturschutz, Umwelt und Geologie [HLNUG] (2023): Bodenerosionsatlas Hessen. www.hlnug.de/themen/boden/auswertung/bodenerosionsbewertung/bodenerosionsatlas, letzter Zugriff 3/2023.
- Kagerer, J., Auerswald, K. (1997): Erosionsprognose-Karten im Maßstab 1:5.000 für Flurbereinigungsverfahren und Landwirtschaftsberatung. In: Schriftenreihe der Bayerischen Landesanstalt für Bodenkultur und Pflanzenbau. Bayerische Landesanstalt für Landwirtschaft. <https://d-nb.info/953562441>, letzter Zugriff 3/2023.
- Oberholzer, G. (1985): Die Berücksichtigung der Bodenerosion durch Wasser in der Flurbereinigungsplanung. In: Schriftenreihe des Wissenschaftlichen Studienganges Vermessungswesen an der Hochschule der Bundeswehr München, Heft 18, 55–93.
- Do, M.N.; Lu, Y.L. (2011): Multidimensional filter banks and multiscale geometric representations. In: Foundations and Trends in Signal Processing, Vol. 5, 157–264. DOI: 10.1561/20000000012, letzter Zugriff 3/2023.
- O’Shea, K., Nash, R. (2015): An Introduction to Convolutional Neural Networks. In: ArXiv e-prints. DOI: 10.48550/arXiv.1511.08458, letzter Zugriff 3/2023.
- Pammer, B. (2015): Untersuchung der radiometrischen Qualität digitaler Orthophotos. In: DGPF Tagungsband 24/2015, 329–336. www.dgpf.de/src/tagung/jt2015/proceedings/papers/37_DGPF2015_KKN_Pammer.pdf, letzter Zugriff 3/2023.
- Panagos, P., Borrelli, P., Poesen, J., Ballabio, C., Lugato, E., Meusburger, K., Montanarella, L., Alewell, C. (2015): The new assessment of soil loss by water erosion in Europe. In: Environmental Science & Policy, Vol. 54, 438–447. DOI: 10.1016/j.envsci.2015.08.012, letzter Zugriff 3/2023.
- Panagos, P., Standardi, G., Borrelli, P., Lugato, E., Montanarella, L., Bossello, F. (2018): Cost of agricultural productivity loss due to soil erosion in the European Union: From direct cost evaluation approaches to the use of macroeconomic models. In: Land Degradation & Development, Vol. 29, Issue 3, 471–484. DOI: 10.1002/ldr.2879, letzter Zugriff 3/2023.
- Pawara, P., Okafor, E., Schomaker, L., Wiering, M. (2017): Data Augmentation for Plant Classification. In: Advanced Concepts for Intelligent Vision Systems (ACIVS2017), Antwerp, Belgium. DOI: 10.1007/978-3-319-70353-4_52, letzter Zugriff 3/2023.
- Schmitt, A. (2012): Änderungserkennung in multitemporalen und multipolarisierten Radaraufnahmen. Doktorarbeit, Institut für Photogrammetrie und Fernerkundung, Universität Fridericiana zu Karlsruhe. <https://publikationen.bibliothek.kit.edu/1000025955>, letzter Zugriff 3/2023.
- Schmitt, A., Wessel, B., Roth, A. (2014): An Innovative Curvelet-only-Based Approach for Automated Change Detection in Multi-Temporal SAR Imagery. In: MDPI Remote Sensing, 2014, Vol. 6, No. 3, 2435–2462. DOI: 10.3390/rs6032435, letzter Zugriff 3/2023.

- Schmitt, A., Wendleder, A., Hinz, S. (2015): The Kennaugh element framework for multi-scale, multi-polarized, multi-temporal and multi-frequency SAR image preparation. In: ISPRS Journal of Photogrammetry and Remote Sensing, Volume 102, 122–139. DOI: 10.1016/j.isprsjprs.2015.01.007, letzter Zugriff 3/2023.
- Schmitt, A. (2016): Multiscale and multidirectional multilooking for SAR image enhancement. In: IEEE Transactions on Geoscience and Remote Sensing, Vol. 54, No. 9, 5117–5134. DOI: 10.1109/TGRS.2016.2555624, letzter Zugriff 3/2023.
- Schmitt, A., Wendleder, A. (2018): SAR-Sharpener in the Kennaugh Framework applied to the fusion of multimodal SAR and optical images. In: ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. IV-1, 133–140. DOI: 10.5194/isprs-annals-IV-1-133-2018, letzter Zugriff 3/2023.
- Schmitt, A., Uth, P., Standfuß, I., Heider, B., Siedentop, S., Taubenböck, H. (2023): Quantitative Assessment and Comparison of Urban Patterns in Germany and the United States. In: Computers, Environment and Urban Systems, Volume 100, No.101920. DOI: 10.1016/j.compenvurbsys.2022.101920, letzter Zugriff 3/2023.
- Schollerer, L., Schmitt, A., Wendleder, A., Rogginger, S. (2022): Schritthaltende Baufallerkundung aus dem All mit frei verfügbaren Satellitenaufnahmen. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 3/2022, 147. Jg., 168–180. DOI: 10.12902/zfv-0391-2022, letzter Zugriff 3/2023.
- Werner, M. (2021): Digitale Bildverarbeitung. Springer Vieweg, Wiesbaden, ISBN: 978-3-658-22185-0.
- Wurm, M., Schmitt, A., Taubenböck, H. (2016): Building Types' Classification Using Shape-Based Features and Linear Discriminant Functions. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 9, No. 5, 1901–1912. DOI: 10.1109/JSTARS.2015.2465131, letzter Zugriff 3/2023.
- Zangl, R., Hauser, S., Schmitt, A. (2022): Leitfaden zum effektiven Einsatz der Bilddatenfusion in der Fernerkundung. In: *gis.Science – Die Zeitschrift für Geoinformation*, Heft 4/2022, 123–147. <https://gispoint.de/artikelarchiv/gis/2022/gisscience-ausgabe-42022/7608-leitfaden-zum-praktischen-einsatz-der-bilddatenfusion-in-der-fernerkundung.html>, letzter Zugriff 3/2023.

Kontakt

Simone Aigner*

Amt für Ländliche Entwicklung Niederbayern

Dr.-Schlögl-Platz 1, 94405 Landau a. d. Isar

aigner-simone@gmx.de

Andreas Schmitt

Institut für Anwendungen des maschinellen Lernens und

intelligenter Systeme (IAMLIS) \\ Hochschule München, Fakultät für

Geoinformation

Karlstraße 6, 80333 München

andreas.schmitt@hm.edu

* corresponding author

Dieser Beitrag ist auch digital verfügbar unter www.geodaesie.info.