

Ein multivariates statistisches Verfahren zur direkten Klassifizierung von Kulturpflanzenarten aus Reflexionsdaten von Feldspektrometermessungen im Gelände

Bernd Zbell

AG GIS und Fernerkundung, Institut für Landschaftssystemanalyse
Leibniz-Zentrum für Agrarlandschaftsforschung (ZALF) e. V. Müncheberg
Eberswalder Strasse 84
D-15374 Müncheberg
bzbell@zalf.de

Abstract: In der räumlich wie zeitlich bedingten Variabilität der Reflexionsspektren von Kulturpflanzenbeständen sind typische und damit übertragbare spektrale Eigenschaften verborgen, die sich als kulturartenspezifische spektrale Signaturen mit multivariaten statistischen Verfahren der Mustererkennung ableiten lassen. Hierfür waren mit einem Feldspektrometer (ASD Field SpecPro) in den Vegetationszeiten 2002–2004 gemessene Reflexionsspektren von zehn Kulturpflanzenarten die Datengrundlage. Nach Entfernung der Wasserabsorptionslinien als Störsignale wurde die Hauptkomponentenanalyse der Spektraldaten zur Zerlegung in Eigenfaktoren, Datenreduktion und Rauschunterdrückung durchgeführt, um kulturartenspezifische spektrale Signaturen abzuleiten (Programm Thermo GRAMS /AI mit PLSplus IQ). Diese Signaturen dienten unter Nutzung der Mahalanobis-Distanz als Ähnlichkeitsmaß in der Diskriminanzanalyse zur Identifizierung von unbekanntem Spektren in Testdatensätzen. Abschließend wurde die Klassifizierungsgenauigkeit für die zehn Kulturpflanzenarten in einer Konfusionsmatrix überprüft.

1 Einleitung

In optischen Fernerkundungsdaten ist eine direkte Klassifizierung von Kulturpflanzenbeständen, d.h. eine Klassifizierung nur unter Nutzung der spektralen Information aus der Reflexion, noch nicht möglich. Diese Schwierigkeit erklärt sich aus der beobachteten räumlichen und zeitlichen Variabilität der Reflexionsdaten, die vor allem durch Unterschiede in der Phänologie der Pflanzen, im Agrarmanagement (Aussaatstärke, Düngerdosierung etc.) und von mikroklimatischen und Standortfaktoren hervorgerufen werden. Folglich gibt es kein eindeutiges, typisches Reflexionsspektrum, d.h. keine spezifische spektrale Signatur für eine bestimmte Kulturpflanzenart. In der vorliegenden Untersuchung wurde im Gelände eine mehrjährige Messkampagne zum Monitoring der Variabilität der Reflexion bei zehn Kulturpflanzenarten durchgeführt, um aus den Reflexionsdaten mittels Hauptkomponentenanalyse und anschließender Diskriminanzanalyse typische und damit übertragbare spektrale Eigenschaften zu gewinnen und diese als spektrale Signaturen für eine direkte Klassifizierung von Kulturpflanzenarten zu nutzen.

2 Methoden

2.1 Reflexionsmessungen und Prozessierung der Reflexionsdaten

In den Vegetationsperioden 2002-2004 wurden mit einem Feldspektrometer ASD FieldSpec Pro im Wellenlängenbereich von 350-2500 nm insgesamt 190000 kontinuierliche Reflexionsspektren bei zehn Kulturpflanzenarten auf den Versuchspartellen des ZALF in Müncheberg gemessen. Aus dem Datenpool wurden 4600 messpunktbezogene Mittelwertsspektren *online* berechnet [Programm ASD RS³]. Nach Entfernung der Wasserabsorptionsbanden in den Spektralbereichen 1350-1420 nm und 1760-1960 nm wurden die Spektren mit dem Savitzky-Golay-Algorithmus mit einem Polynom 4. Grades geglättet [Programm: Thermo GRAMS/AI] (Abb. 1). Die räumliche und zeitliche Variabilität der Reflexionsdaten ist für Winterraps- und Winterweizenbestände in Abb. 2 beispielhaft dargestellt. Weitere untersuchte Kulturpflanzenarten waren Silomais, Winterroggen, Wintergerste, Triticale, Erbse, Kartoffel, Knaulgras und Luzerne-Klee-Gras.




Abbildung 1: Ein Mittelwertreflexionsspektrum mit Wasserabsorptionslinien (links) und nach deren Entfernung mit Unterteilung in die Spektralbereiche des XYZ-Plots (rechts).

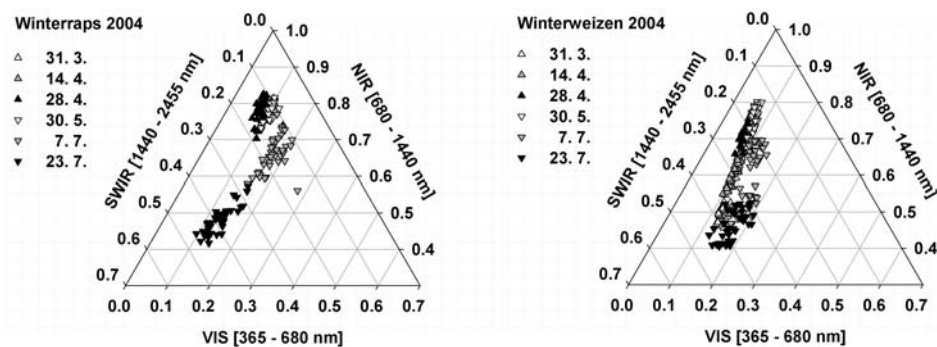


Abbildung 2: XYZ-Plots der Reflexion von Winterraps- bzw. Winterweizenbeständen im Jahr 2004. Die zeitliche Variabilität der Reflexionsdaten wird durch unterschiedliche Symbole, die räumliche Variabilität durch die Streuung gleichartiger Symbole dargestellt.

2.2 Hauptkomponentenanalyse (PCA)

Für jede Kulturpflanzenart wurden alle während einer Vegetationszeit gemessenen Reflexionsspektren als Trainings- bzw. Testdaten zusammengefasst. Für die Ableitung von spektralen Signaturen für jede Kulturpflanzenart wurden mit der Hauptkomponentenanalyse (PCA) [Programm: Thermo PLSplus IQ] die Reflexionsspektren in eine begrenzte Anzahl untereinander unabhängiger Variabler zerlegt, die die Varianz der Trainingsdaten mit Eigenwerten, Faktoren und Korrelationskoeffizienten in einer multiplen linearen Regression nahezu vollständig beschreibt (Abb. 3). Mit dem Verfahren wurde der Datenumfang durch Entfernung von redundanter Information stark reduziert. Die PCA wurde als Kreuzvalidierung durchgeführt, die unbekannte Proben vorhersagt, indem bei jedem Rechenschritt ein anderes Reflexionsspektrum aus den Trainingsdaten entfernt wird, und die Berechnung solange wiederholt wird, bis alle Reflexionsspektren getestet sind.

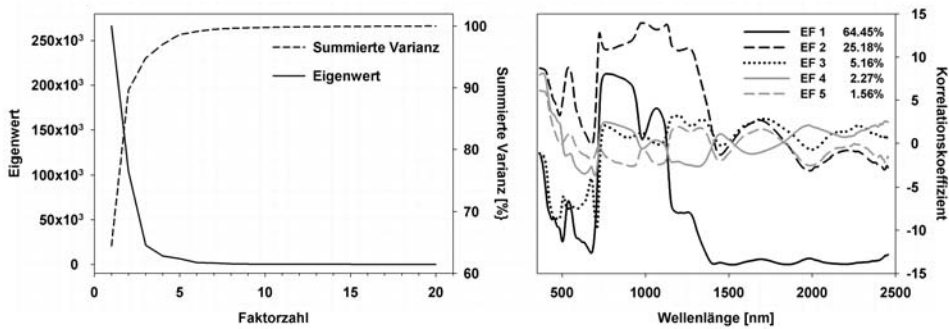


Abbildung 3: Hauptkomponentenanalyse (PCA) der Reflexionsdaten für Winterrapsbestände im Jahr 2003. Der *Scree-Plot* (links) trennt *sekundäre* Eigenfaktoren – das Geröll (engl. *scree*) – von *primären* Faktoren (steiler Hang), d.h. den Bereich mit dem größten Informationsgehalt. Die *primären* Faktoren sind mit Angabe der Varianz als Funktion der Wellenlänge dargestellt (rechts).

2.3 Diskriminanzanalyse

Mittels PCA wurden aus den Trainingsdaten für jede Kulturpflanzenart spektrale Signaturdaten abgeleitet, die in der Diskriminanzanalyse für die direkte Klassifizierung, d.h. nur unter Nutzung der spektralen Information aus der Reflexion der Kulturpflanzenarten eingesetzt wurden. Dabei diente die Mahalanobis-Distanz (M-Distanz) als statistisches Maß der Ähnlichkeit von Signatur- und Testdaten. Die Diskriminanzanalyse [Programm: Thermo PLSplus IQ] wurde für jede Kulturpflanzenart mit 20 spektralen Signaturen (Eigenfaktoren 1-20) in einem definiertem Bereich der M-Distanz (1-20) durchgeführt. Bei der Klassifizierung gab es vier mögliche qualitative Zuordnungen: *positiv richtig*, *negativ richtig*, *positiv falsch* sowie *negativ falsch*, und diese Ergebnisse wurden in einer Konfusionsmatrix als Klassifizierungsgenauigkeit quantitativ ausgewertet (Abb. 4).

Spectrum	Crop Type	Match	MDistance	Limit Tests	Spec Residual	F-Ratio	F-Test	F=11_md1	WRP	XCROP	F=11_md1.4	WRP	XCROP	F=11_md20	WRP	XCROP
#01	WHEAT	NO	23.725	FAIL (FFF#)	0.136	43.394	1.000	XCROP	0	1	XCROP	0	1	XCROP	0	1
#02	WHEAT	NO	23.893	FAIL (FFF#)	0.138	43.837	1.000	XCROP	0	1	XCROP	0	1	XCROP	0	1
#03	POTATO	NO	6.409	FAIL (FFF#)	0.034	10.904	0.998	XCROP	0	1	XCROP	0	1	XCROP	1	0
#04	WRAPE	YES	0.950	PASS (PPP#)	0.001	0.310	0.419	WRP	1	0	WRP	1	0	WRP	1	0
#05	WRAPE	NO	1.212	FAIL (PPF#)	0.000	0.130	0.323	WRP	0	1	WRP	1	0	WRP	1	0
#06	POTATO	NO	3.570	FAIL (F#F#)	0.014	4.450	0.966	XCROP	0	1	XCROP	0	1	XCROP	1	0
#07	WHEAT	NO	8.964	FAIL (FFF#)	0.054	17.060	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#08	WHEAT	NO	17.158	FAIL (FFF#)	0.100	31.733	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#09	WBARLEY	NO	8.061	FAIL (FFF#)	0.048	15.433	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#10	WRYE	NO	6.868	FAIL (FFF#)	0.041	13.189	0.999	XCROP	0	1	XCROP	0	1	XCROP	1	0
#11	PEA	NO	3.148	FAIL (P#F#)	0.019	6.175	0.987	XCROP	0	1	XCROP	0	1	XCROP	1	0
#12	TRITCALE	NO	16.095	FAIL (FFF#)	0.094	29.997	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#13	TRITCALE	NO	16.086	FAIL (FFF#)	0.093	29.683	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#14	PEA	NO	2.894	FAIL (P#F#)	0.018	5.834	0.984	XCROP	0	1	XCROP	0	1	XCROP	1	0
#15	WRYE	NO	12.092	FAIL (FFF#)	0.070	22.317	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#16	WBARLEY	NO	24.690	FAIL (FFF#)	0.142	45.131	1.000	XCROP	0	1	XCROP	0	1	XCROP	0	1
#17	WRAPE	YES	0.627	PASS (PPP#)	0.001	0.330	0.429	WRP	1	0	WRP	1	0	WRP	1	0
#18	WRYE	NO	9.558	FAIL (FFF#)	0.056	17.869	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#19	WBARLEY	NO	17.536	FAIL (FFF#)	0.101	32.292	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#20	SMAIZE	NO	16.819	FAIL (FFF#)	0.093	29.490	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#21	SMAIZE	NO	7.751	FAIL (FFF#)	0.039	12.369	0.999	XCROP	0	1	XCROP	0	1	XCROP	1	0
#22	WBARLEY	NO	5.637	FAIL (FFF#)	0.035	11.070	0.999	XCROP	0	1	XCROP	0	1	XCROP	1	0
#23	WRYE	NO	6.869	FAIL (FFF#)	0.041	13.093	0.999	XCROP	0	1	XCROP	0	1	XCROP	1	0
#24	WRAPE	YES	0.634	PASS (PPP#)	0.001	0.344	0.437	WRP	1	0	WRP	1	0	WRP	1	0
#25	TRITCALE	NO	2.082	FAIL (PPF#)	0.009	2.973	0.918	XCROP	0	1	XCROP	0	1	XCROP	1	0
#26	WRYE	NO	11.363	FAIL (FFF#)	0.068	21.512	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#27	ALFALFA	NO	12.369	FAIL (FFF#)	0.073	23.101	1.000	XCROP	0	1	XCROP	0	1	XCROP	1	0
#28	COCKS	NO	4.789	FAIL (FFF#)	0.029	9.266	0.997	XCROP	0	1	XCROP	0	1	XCROP	1	0

Calibration File	Crop A	XCROP	SITES_ACC
Crop A	positive right	positive false	%
XCROP	negative false	negative right	%
CLASS_ACC	%	%	K = %

WRP_F=11_md1	WRP	XCROP	SITES_ACC
Winter rape	3	1	75.00%
XCROP	0	24	100.00%
CLASS_ACC	100.00%	96.00%	K = 83.72%

WRP_F=11_md1.4	WRP	XCROP	SITES_ACC
Winter rape	4	0	100.00%
XCROP	0	24	100.00%
CLASS_ACC	100.00%	100.00%	K = 100.00%

WRP_F=11_md20	WRP	XCROP	SITES_ACC
Winter rape	4	0	100.00%
XCROP	21	3	12.50%
CLASS_ACC	100.00%	98.77%	K = 3.92%

Abbildung 4: Diskriminanzanalyse unter Nutzung der Mahalanobis-Distanz für die Zuordnung der spektralen Signaturen von Winterrapsbeständen mit Testdaten. Ergebnisübersicht (oben) und Konfusionsmatrizes zur Berechnung der Klassifizierungsgenauigkeit (unten).

2.4 Validierung

Als statistisches Maß der Klassifizierungsgenauigkeit in der Diskriminanzanalyse wurde der kappa- (κ) Koeffizient berechnet. Ein κ -Koeffizient von 0 % zeigt keine Übereinstimmung zwischen Trainings- und Testdaten an, während ein κ -Koeffizient von 100 % ihre vollständige Übereinstimmung nachweist. Ein schwieriges Problem bei der Ableitung der spektralen Signaturen aus der PCA ist das Finden der optimalen Kombination der Anzahl von Eigenfaktoren und M-Distanzwerten zur spektralen Zuordnung in der Diskriminanzanalyse. Es ist sinnvoll, genügend *primäre* Eigenfaktoren für eine ausreichende Zuordnung zu berücksichtigen, ohne *sekundäre*, sogenannte Rauschfaktoren hinzuzufügen, die typisch für die Trainings-, aber nicht für die Testdaten sind. Bei der Anwendung der spektralen Signaturen zeigt die Klassifizierung der zehn Kulturpflanzenarten nämlich das Phänomen der Überschätzung bei den Trainingsdaten ($\kappa > 70$ %), aber das einer Unterschätzung ($\kappa < 10$ %) bei den Testdaten, wenn die Anzahl der Eigenfaktoren und die M-Distanzwerte nicht durch gegenseitige Anpassung optimiert werden. In diesem Fall reduziert sich z.B. bei den Trainingsdaten 2003 die Klassifizierungsgenauigkeit von $\kappa = 83,0$ % auf $\kappa = 48,3$ %, während sie sich bei den Testdaten 2002 von $\kappa = 14,7$ % auf $\kappa = 39,1$ % erhöht.