

Michael Fritsch

In eigener Sache

Elektronische Zeitschrift für Agrarinformatik

Liebe Leserinnen und Leser der Zeitschrift für Agrarinformatik,

die 04/2005 ist die letzte Ausgabe unserer Zeitschrift für Agrarinformatik als Printmedium. Die Gesellschaft für Informatik in Ernährungs-, Land- und Forstwirtschaft, Gartenbau und Umwelt hat sich dafür entschieden, beginnend mit dem Jahr 2006, ihre Zeitschrift in elektronischer Form zu veröffentlichen. Die Zeitschrift wird dann per Email an alle Leser verteilt werden und auch auf dem Internet-Server der GIL unter www.gil.de verfügbar sein.

Ich möchte hier nochmals die Gelegenheit nutzen, allen Autoren und Gutachtern für die bisherige aktive und konstruktive Mitarbeit an unserer Printzeitschrift zu danken.

Der Aufbruch in eine neue Form der Publikationsart ist für uns auch gleichzeitig Ansporn für die Erhaltung und Verbesserung der inhaltlichen Qualität unserer Zeitschrift.

Unter diesem Aspekt möchte ich alle Mitglieder der GIL und alle Leser dieser Zeitschrift ermutigen, aus ihren Projekten und Arbeiten Artikel zur Veröffentlichung in unserer Zeitschrift einzureichen.

Ich wünsche uns für die Zukunft weiterhin eine interessante und inhaltlich hochwertige elektronische Zeitschrift sowie ein erfolgreiches Jahr 2006.

 Aus Wissenschaft und Forschung – Scientific Articles

P. Wagner, M. Schneider, G. Weigert

Einsatz künstlicher Neuronaler Netze zur automatisierten Ableitung von Entscheidungsregeln für die N-Düngung in Winterweizen

Zur teilflächenspezifischen Bewirtschaftung von Feldern sind Entscheidungsregeln notwendig, die kleinräumigen Standortunterschieden Rechnung tragen. Der vorliegende Beitrag gibt ein Beispiel, wie unter Zuhilfenahme künstlicher Neuronaler Netze solche Regeln für die teilflächenspezifische Stickstoffdüngung erstellt werden können.

1 Einleitung

Die Forschung in Bezug auf automatisierte Generierung von Entscheidungsregeln für den teilflächenspezifischen Pflanzenbau steckt noch in den Kinderschuhen. Entsprechend wenig Literatur ist zu diesen Punkten bisher zu finden. Andererseits gilt als anerkannt, dass eine der Hauptursachen für den Nichteinsatz der Precision-Farming-Technologie fehlende Entscheidungsregeln für die Düngung sind (LOWENBERG-DeBOER, 1996, S. 1283): "One of the key factors limiting adoption of precision farming technology is the lack of decision support. There is too much data to sort and analyze manually or mentally,

and little software to automate the process. Someone needs to estimate the surface-generating production function ... someone needs to develop the optimization algorithm that will apply that information to generating next season's cropping strategy." Mit dem hier vorliegenden Beitrag soll ein Ansatz gezeigt werden, zumindest einen Teil der aufgezeigten Lücke zu füllen.

Vielfältige Variablen werden notwendig sein, um sachgerechte Entscheidungsregeln bezüglich der Stickstoffdüngung ableiten zu können. In den allermeisten der in der Literatur vorliegenden Beiträge werden jeweils einzelne Variablen herausgegriffen und Abhängigkeiten zur Düngung hergestellt.

Beispielsweise stellen LUND, CHRISTY und DRUMMOND (1999) deutliche Zusammenhänge zwischen der scheinbaren elektrischen Leitfähigkeit des Bodens und dem Ertrag dar und leiten ansatzweise Entscheidungsregeln für die Aussaatstärke in Abhängigkeit von scheinbarer elektrischer Leitfähigkeit sowie Stickstoffdüngung in Abhängigkeit von Leitfähigkeit (S. 777) ab. Diese Entscheidungsregeln sind allerdings zu vage, als dass sie konkret eingesetzt werden könnten. Weiterhin wird die Notwendigkeit beschrieben, Leitfähigkeitsdaten mit anderen Informationslagen zu verschneiden, um Entscheidungsregeln bezüglich der Düngung abzuleiten (S. 771). Auch auf unseren Versuchsschlägen am Südostrand der Magdeburger Börde nördlich von Halle haben wir hohe positive Korrelationen zwischen scheinbarer elektrischer Leitfähigkeit und Ertrag feststellen können.

Andererseits schreiben HUANG, KRAVCHENKO und THELEN (2005, S.429): „Generally, low EC [Electrical Conductivity (Anm. d. Autors)] values corresponded to high yield clusters in the studied fields“. Wenn beide Aussagen richtig sind, sind offensichtlich die Verhältnisse von Standort zu Standort verschieden.

Oftmals werden Ertragskarten als Grundlage von Precision-Farming-Maßnahmen gesehen. BLACKMORE, GODWIN und FOUNTAS (2003, S.465) haben nach der Analyse mehrjähriger Ertragskarten identischer Schläge herausgearbeitet, dass „Significant spatial variability is evident in most individual yield maps, which were expected to stabilize into areas of consistent trends after a few years. This can now be seen as untrue as the maps become more homogeneous over time.“ Auf unseren Versuchsschlägen wiederum haben wir eine ausgeprägte Stabilität der Ertragsmuster über die Zeit feststellen können. LISSO (2003) nimmt, allerdings mittels Luftbild um Fehler korrigierte, Ertragskarten, die auch bei ihm stabile Muster aufweisen, als Basis seiner Entscheidungen zur teilflächenspezifischen Aussaat, Düngung und zum teilflächenspezifischen Ausbringen von Fungiziden und Wachstumsreglern.

PETERS et al. (1999) versuchen Stickstoffmanagementstrategien herauszuarbeiten, weil auch diese Autoren erkennen, dass (S. 719) "... one of the perceived constraints on the adoption of precision farming techniques by farmers is the lack of readily available, definitive guidelines on variable rate nitrogen fertilizer management." In ihrem Beitrag wird auch (S. 720) ein Versuchsansatz beschrieben, der dazu dienen soll, Entscheidungsregeln für die Stickstoffdüngung abzuleiten. Bei den dargestellten Erkenntnissen geht es im Wesentlichen um die Identifikation verschiedener Bodenarten und um Vergleiche bezüglich der Ertragsfähigkeit sowie der Ertragsbildung für Pflanzen unter identischen Düngestrategien.

Die Beschreibung der Versuchsergebnisse ist viel versprechend, die Autoren kommen allerdings nicht zu den vom Leser anfänglich erhofften konkreten Entscheidungsregeln.

Auch im deutschsprachigen Raum wird von einigen Forschergruppen an Entscheidungsregeln für die Stickstoffdüngung im Precision-Farming gearbeitet. ISENSEE, THIESSEN und ENGELN (2000) gehen von einem theoretischen Modell der Entscheidungsfindung aus. Inputparameter seien Ertragsfähigkeit (Boden, Wasserverhältnisse, Relief usw.), Witterungsverhältnisse (Bodenfeuchte, N-Nachlieferung usw.), Sortentyp (Bestockungsverhalten, Ertragsaufbau) und Optimierungen weiterer pflanzenbaulicher Parameter (PSM, Spurennährstoffe usw.). Konkrete Entscheidungsregeln werden allerdings auch hier nicht abgeleitet.

WELSH et al. (1999) weisen ebenfalls auf die Notwendigkeit der Identifikation homogener Managementeinheiten hin und vor allem darauf, dass wohl jede Managementeinheit eine spezifische Produktionsfunktion aufweise (S. 737). An gleicher Stelle weisen die Autoren auch darauf hin, dass es Möglichkeiten zur Verallgemeinerung dieses Sachverhaltes geben müsste, allerdings ohne sie selbst zu liefern.

WENKEL et al. (2001) stellen ebenfalls Entscheidungsregeln für eine Stickstoffempfehlung im teilflächenspezifischen Pflanzenbau auf (S. 745) und präsentieren in WENKEL et al. (2004) Module zur ortsspezifischen N- und Grunddüngung, die sich an die Empfehlungen der VDLUFA anlehnen. Die Ergebnisse von Feldversuchen waren positiv, statistisch jedoch nicht abzusichern (Kap. 4, S. 154f). Dessen ungeachtet ist die zur Anwendung der Entscheidungsregeln vorausgesetzte Informationsdichte prohibitiv hoch.

Insgesamt kann derzeit von einer nur unbefriedigenden Situation bezüglich umsetzbarer Entscheidungsregeln für die Stickstoffdüngung im teilflächenspezifischen Pflanzenbau ausgegangen werden. Teilweise widersprüchliche Aussagen lassen vermuten, dass es ein Patentrezept nicht gibt und für jeden Standort andere Entscheidungsregeln vorzüglich sind. Allenfalls scheinen sich Ergebnisse in klimatisch entsprechenden Regionen von einem Standort auf den anderen übertragen zu lassen.

Vor diesem Hintergrund erscheinen „selbstlernende“ Algorithmen ein gangbarer Weg. Solche Algorithmen lassen sich mit Techniken des „Data Mining“ entwickeln. Dieser vorliegende Beitrag stellt das Ergebnis einer solchen Entwicklung vor. Als besonders vorteilhaft ist herauszustellen, dass die hier präsentierte Methode prinzipiell standortunabhängig arbeitet, m.a.W. auf jedem Standort einsetzbar sein dürfte. Sie setzt zwar eine hohe Informationsdichte voraus, die notwendigen, flächenmäßig hochauflösenden Informationen lassen sich allerdings automatisiert, und damit zu niedrigen Kosten, erheben!

2 Data Mining

2.1 Anwendungen von Data Mining Techniken

Bezüglich der für diesen Beitrag umzusetzenden Methodik des "Data-Mining" existiert eine breite Vielfalt an Literatur, allerdings kaum im agrarwissenschaftlichen Kontext. Einen Überblick geben beispielsweise NAKHAEIZADEH et al. (1998). Dort werden existierende Techniken, Werkzeuge und Anwendungen in wissenschaftlicher Forschung und industrieller Praxis dargestellt. All diese Anwendungen beruhen zum Großteil auf finanzwirtschaftlichen Fragestellungen (vgl. BAETGE und UTHOFF, 1998). Dort werden hauptsächlich Klassifikationsprobleme behandelt. Unter anderem um Klassifikationsprobleme, aber auch um Abhängigkeitsanalysen (NAKHAEIZADEH et al., 1998, S.10 und 16ff.) dürfte es im Wesentlichen auch bei der Identifizierung homogener Teilflächen und der Ableitung von Düngestrategien gehen. Literatur hinsichtlich landwirtschaftlicher Anwendungen ist kaum zu finden.

KOLLIG (1993) setzte Neuronale Netze und regelbasierte Systeme ein, um ein Entscheidungsunterstützungsmodul für den Zuckerrübenanbau zu entwickeln. In dieser Arbeit konnte erstmalig durch ein Neuronales Netz die Quantifizierung von Einflussparametern auf den Rübenanbau gezeigt werden.

HOSKINSON, HESS und FINK (1999) beschreiben den Versuch, mittels Data-Mining-Techniken ansatzweise Entscheidungsregeln für Düngestrategien abzuleiten und erzielen damit erste, ermutigende Ergebnisse. KITCHEN et al. (2003) prognostizieren mit Hilfe eines Neuronales Netzes auf Basis von scheinbarer elektrischer Leitfähigkeit und Topographie Erträge. CHAUDHARY et al. (2005) kommen zum Ergebnis, dass sich mit Data-Mining-Techniken Möglichkeiten bieten, ertragsbeeinflussende Faktoren zu analysieren. DIKER et al. (2005) prognostizieren Erträge, indem sie ein Neuronales Netz trainieren.

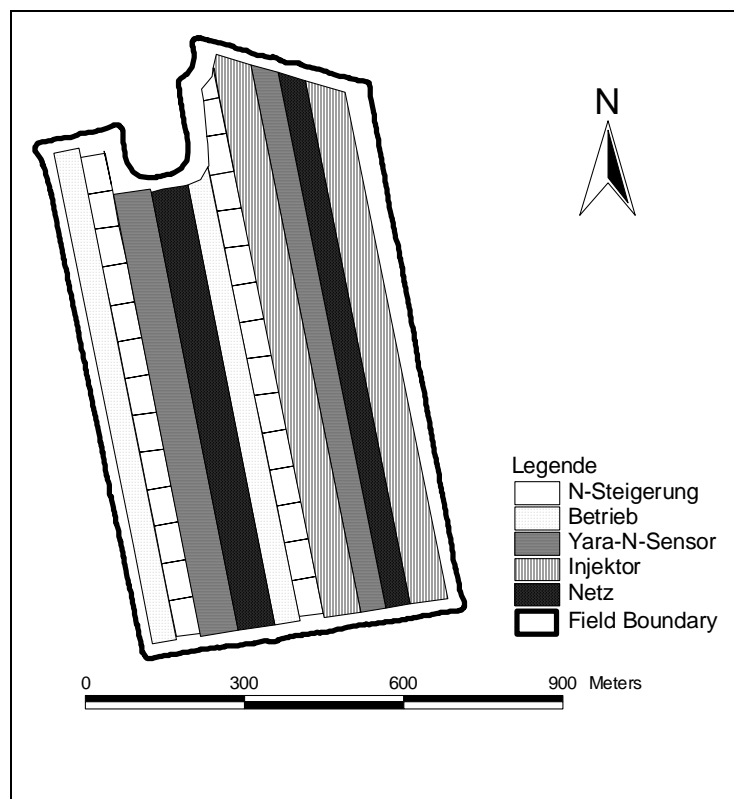


Abbildung 1: Versuchsdesign Schlag 350

In keinem der Autoren bekannten Beiträge werden so konkrete und vor allem in der Praxis ohne weiteres umsetzbare Entscheidungsregeln herausgearbeitet wie sie hier weiter unten vorgestellt werden.

2.1 Künstliche Neuronale Netze (KNN)

„Ein KNN ist die Kombination einer komplizierten nichtlinearen Funktion mit einem einfachen „Lern“-Algorithmus, der durch iterative oder rekursive Vorgehensweise aus vorhandenen Eingangs- und gewünschten Ausgangswerten alle Parameter der Funktion zu bestimmen

versucht. ...KNN haben im Vergleich zu anderen Gebieten der künstlichen Intelligenz, z.B. den Expertensystemen ihren Anwendungsschwerpunkt dort, wo ein Rechner durch einige wenige ausgewählte Eingabemuster lernen soll, ein beliebiges Eingabemuster in das gewünschte Ausgabemuster zu überführen.“ (WIKIPEDIA, Stichwort „künstliches Neuronales Netz (23.11.2005)“). Künstlich werden die KNN bezeichnet, um sicherzustellen, dass es sich um eine künstliche Einheit und nicht um die wirklichen biologischen Neuronales Netze handelt, wie sie beim Menschen anzutreffen sind.

KNN sind bei allen Anwendungen interessant, bei denen kein oder nur geringes Wissen über das zu lösende Problem vorliegt. KNN sind auch dort anwendbar, wo regressionsstatistische Ansätze versagen, etwa weil die erklärenden Variablen nicht von einander unabhängig sind oder weil Autokorrelation vorliegt.

Literatur über KNN existiert in großen Mengen, exemplarisch sei auf CALLAN (2003) verwiesen, der die grundlegenden Konzepte behandelt. Für die Anwendung im Bereich der Landwirtschaft beschreibt KOLLIG (1993, S.33ff) die Arbeitsweise eines KNN mit Hilfe eines Pseudocodes und arbeitet auch sehr anschaulich heraus, wie die Ergebnisse eines KNN zu interpretieren sind. In engem Bezug zu dem hier vorliegenden Beitrag steht die Arbeit von WEIGERT (2006), die ebenfalls ein Kapitel über die Arbeitsweise von KNN enthält. WEIGERT legt den Schwerpunkt dabei auf die Lernphase und die Datenvorbereitung.

3 Einsatz eines KNN zur Ableitung von Entscheidungsregeln

Zur teilflächenspezifischen Ertragsprognose wurde ein künstliches neuronales Netz trainiert und innerhalb eines Feldversuches zur Stickstoffdüngung angewendet. Zum Vergleich wurden zusätzlich drei weitere teilflächenspezifische und schlageinheitliche Düngestrategien durchgeführt.

3.1 Versuchsaufbau

Der Feldversuch wurde im Anbaujahr 2004/05 auf dem Schlag 350 (51°40'N 11°58'E) der Domäne Görzig, dem Lehr- und Versuchsgut der Universität Halle, angelegt. Die darauf angebaute Fruchtart Winterweizen wurde nach den vier unterschiedlichen Düngestrategien (Versuchsglieder): „Betriebsüblich“, „Sensor“, „Injektor“ und „Netz“ mit Stickstoff versorgt.

Der Standort lässt sich folgendermaßen charakterisieren: Mit einer durchschnittlichen Jahressumme des Niederschlages von 475 mm, gehört die Region zum Mitteldeutschen Trockengebiet. Die Jahrestemperatur liegt im Durchschnitt bei 9 °C. Das Gelände befindet sich zwischen 90 und 100 Metern über Normal Null und ist als eben einzustufen.

Der Schlag hat eine Größe von 63 Hektar. Die durchschnittliche Bodenwertzahl beträgt 73. Bodentypologisch handelt es sich um eine Schwarzerde aus Löß. Die Bodenart des Standortes ist ein stark toniger Schluff (Ap Horizont, 0-30 cm: Ton: 19,3%, Schluff: 72,8%, Sand: 7,9%).

Im Versuchszeitraum wurde die Winterweizensorte „Compliment“ (A-Weizensorte) angebaut (Vorfrucht: Winterraps). Die Aussaat fand am 10.09.2004 statt. Der N_{\min} Gehalt für diesen Schlag wurde im Frühjahr 2005 auf 32 kg N/ha bestimmt.

In einem Streifendesign wurden die vier Versuchsglieder auf dem Schlag angelegt. Jedes Glied wurde in zwei Streifen wiederholt (siehe Abbildung 1). Die Streifen hatten jeweils eine Breite von zwei bzw. drei Fahrspuren bei einer Arbeitsbreite der Düngetechnik von 24 Metern.

Auf eine zufällige Verteilung der Wiederholungen im Feld wurde absichtlich verzichtet. Dies findet Begründung im begrenzten Platzumfang des Schlages und der damit verbundenen niedrigen Anzahl an Wiederholungen. Für jeden Streifen wurde das arithmetische Mittel der räumlich interpolierten Bodenleitfähigkeitsmessung und des Ertrages 2003 bestimmt. Die Aufteilung der Wiederholungen auf die Streifen erfolgte so, dass jedem Versuchsglied annähernd der gleiche durchschnittliche Wert dieser Heterogenitätsindikatoren zukam. Dieses Vorgehen findet seine Begründung im späteren Vergleich der Ertragsergebnisse (Mittelwerte), der dadurch annähernd ermöglicht wird.

Zusätzlich wurden Stickstoffsteigerungspartellen auf dem Schlag angelegt. Dazu wurde die applizierte Stickstoffgesamtmenge von 0 bis 270 kg/ha variiert. Die Steigerungspartellen werden zum Training des künstlichen Neuronalen Netzes benötigt.

Die Durchführung der Bewirtschaftungsmaßnahmen erfolgte mit praxisüblicher Technik eines Landwirtschaftsbetriebes aus dieser Region. Abgesehen von der Höhe der Stickstoffdüngung der teilflächenspezifischen Versuchsglieder wurden alle weiteren pflanzenbaulichen Entscheidungen vom Leiter dieses Betriebes getroffen. Folgend werden die einzelnen Düngestrategien näher vorgestellt:

Betrieb

Die betriebsübliche Düngewarante wurde schlageinheitlich ausgebracht. In die Entscheidungsfindung flossen langjährige Anbauerfahrungen eines Pflanzenbauexperten mit der Fruchtart Winterweizen auf diesem Standort ein. Die Düngung wurde nach dem erwarteten Nährstoffzug geplant. Das durchschnittliche Ertragsziel für diesen Schlag legte der Pflanzenbauleiter auf 80 dt/ha fest. Unter der Berücksichtigung des Stickstoffbedarfs von 2,6 kg/dt (Haupt- und Nebenernteprodukt) und des im Frühjahr gemessenen N_{\min} Gehaltes mussten insgesamt 175 kg N/ha mineralisch aufgedüngt werden. Die Gesamtmenge sollte in mindestens 3 Gaben aufgeteilt ausgebracht werden.

Zur ersten Gabe wurden 55 kg N/ha appliziert. In die Entscheidung dazu flossen die Informationen zur Vorfrucht (Art und Erntemengen) und zum gemessenen N_{\min} Gehalt ein. Die zweite Gabe wurde auf 60 kg N/ha bemessen. Neben der aktuellen Bestandessituation zum Applikationszeitpunkt (Bonituren), basierte diese Mengenentscheidung hauptsächlich auf den langjährigen Erfahrungen zu dieser Gabe.

Zur dritten Gabe wurden 60 kg N/ha ausgebracht. Neben den Bonituren des Pflanzenbestandes floss in die Entscheidungsfindung der bisherige und erwartete Witterungsverlauf mit ein. Zum Applikationszeitpunkt wurde das Wettergeschehen als durchschnittlich für den Standort angesehen. Daraufhin wurde am Ertragsziel von 80 dt/ha festgehalten.

Wären zu diesem Zeitpunkt zusätzliche Niederschläge erwartet worden, so wäre das Ertragsziel erhöht und die dritte Gabe nochmals aufgeteilt worden (3a und 3b).

Der Pflanzenbauleiter hätte dann zwei Gaben von 50 kg N/ha (3a) und 30 kg N/ha (3b) veranlasst. (persönliche Mitteilung des Pflanzenbauleiters „Hof Pfaffendorf“).

Sensor

Zu diesem Versuchsglied wurde zur Bestimmung des Stickstoffdüngedarfs der Yara-N-Sensor© eingesetzt. Dieses System ermittelt aus der aktuellen Bestandessituation den Nährstoffbedarf und steuert im Online-Verfahren die Applikation des Düngerstreuers. Dabei wird die vom Bestand reflektierte Sonneneinstrahlung erfasst. Darüber lassen sich indirekt Rückschlüsse auf den Chlorophyllgehalt ziehen, der wiederum im Zusammenhang mit dem Stickstoffgehalt in der grünen Biomasse steht. Zur genaueren Beschreibung des Prinzips sei auf LINK et al. (2002) verwiesen.

Der Einsatz des Sensors setzt eine ausreichende Bodenbedeckung durch den Pflanzenbestand voraus. Deshalb wurde die erste Stickstoffgabe flächeneinheitlich, entsprechend des Versuchsgliedes „Betrieb“, durchgeführt.

Injektor

Die Stickstoff Aufwandmenge zu diesem Versuchsglied wurde nach einem „Mapping-Ansatz“ festgelegt. In die Entscheidungsfindung flossen die Informationen der Ertragskarte 2004, sowie die Ertragsdurchschnitte aus drei historischen Winterweizenernten des Schlates ein.

Die räumlich interpolierten (20x20 Meter) Ertragswerte der Ertragskarte 2004 wurden in drei Klassen gleichen Intervalls eingeteilt. Dadurch wurden drei verschiedene Ertragspotenzialzonen eingeteilt. Über die prozentualen Ab- bzw. Zuschläge des Ertragsdurchschnitts der mittleren Ertragsklasse zu den Ertragsdurchschnitten der besseren bzw. schlechteren Ertragsklasse, wurden die durchschnittlichen Erträge der jeweiligen Klassen der drei historischen Winterweizenernten ermittelt. Darüber konnte das durchschnittliche Ertragspotenzial jeder der drei Klassen berechnet werden. Die Stickstoffapplikationskarte wurde nach den erwarteten Nährstoffentzügen der jeweiligen Potenzialzonen erstellt. Für die schlechte (mittlere bzw. gute) Zone wurden eine Applikationsmenge von 165 kg N/ha (185 kg N/ha bzw. 220 kg N/ha) festgelegt. Es sei erwähnt, dass der Flächenanteil der mittleren Zone mit 83 % an der Gesamtfläche den größten Anteil hatte.

Die Stickstoffdüngung zu diesem Versuchsglied erfolgte nach dem „CULTAN“ (Controlled Uptake Long Term Ammonium Nutrition) Verfahren. Dabei bleibt eine Aufteilung der Gesamtdüngermenge in mehrere Teilgaben aus. Zu Beginn der Vegetationszeit wird im Wurzelbereich der Pflanzen die gesamte Düngermenge in Form von Ammonium platziert. Zur näheren Beschreibung der Methode sei auf SOMMER (2003) verwiesen.

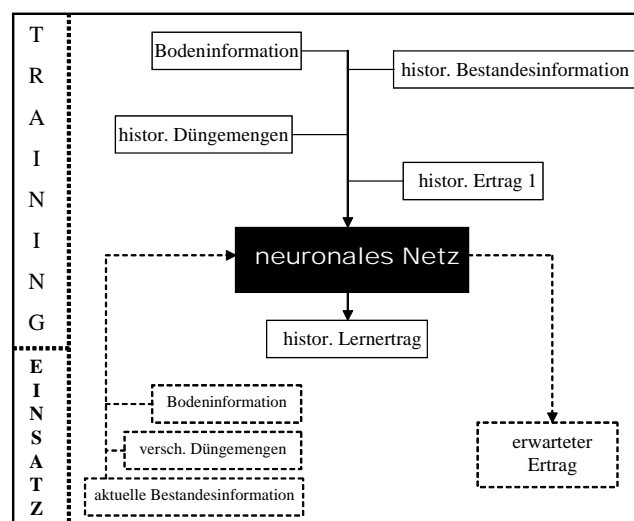


Abbildung 2: Training und Anwendung des neuronalen Netzes

Netz

Die erstellten Entscheidungsregeln zu diesem Versuchsglied basieren auf Ertragsprognosen von künstlichen Neuronalen Netzen. Dafür standen in einer Datenbank Informationen zum Boden (scheinbare elektrische Leitfähigkeit, EC), historischen Erträgen (Jahr 2003 und 2004), historischen Bestandessituationen in Form des REIP (Red Edge Inflection Point) Indices (Jahr 2004) und Düngemengen (Jahr 2004) auf Teilflächenbasis zur Verfügung. Diese Daten stammen allerdings nicht vom weiter oben vorgestellten Versuchsschlag selbst sondern wurden auf einem benachbarten Schlag im Vorjahr gesammelt und dort auf ein Raster von 10x10 Meter räumlich interpoliert.

Auf Grundlage dieser Datenbank wurde für jede der drei Stickstoffgaben jeweils ein Neuronales Netz trainiert. Zum Training des Netzes der ersten Stickstoffapplikation wurden die historischen Ertragsdaten, die Stickstoffgabe der ersten Applikation 2004 und die Leitfähigkeitsdaten genutzt. Für die Netze der zweiten und dritten Stickstoffgabe wurden jeweils zusätzlich die entsprechenden Vorjahresdüngemengen und –bestandessituationen mit einbezogen.

Dafür wurde vor der jeweiligen Stickstoffgabe (EC Stadium 32 und 49 der Weizenpflanzen) eine Sensorüberfahrt (Yara-N-Sensor®, „Fieldscanmodus“) durchgeführt, wonach der REIP bestimmt wurde. Dieser Index enthält Informationen zur aktuellen Stickstoffversorgung des Bestandes. Alle drei neuronalen Netze wurden auf den Ertrag 2004 als Output- bzw. Lernertrag trainiert. Abbildung 2 zeigt das schematische Vorgehen.

Zur Anwendung kam die Software Clementine® der Firma SPSS. Das Training des Neuronalen Netzes läuft so ab, dass während des Lernverfahrens der Outputwert des im Training befindlichen Neuronalen Netzes mit dem tatsächlichen Zielwert des Datensatzes verglichen wird (hier: Ertrag 2004). Die Abweichung zwischen diesen beiden Werten dient als Steuersignal zur weiteren Entwicklung der Netzstruktur. Dieses Verfahren wird Backpropagation-Algorithmus genannt. Zur näheren Beschreiben sei auf WEIGERT (2006) verwiesen.

Vor den einzelnen Stickstoffgaben 2005 wurde das entsprechende Netz mit den tatsächlichen Standortgegebenheiten der einzelnen Teilflächen des Schlates 350 zur Ertragsprognose angewendet (siehe Abbildung 2). Dazu wurden die Auswirkungen aller technisch möglichen Applikationshöhen der jeweiligen Gabe (0 bis 100 kg N/ha) auf den Ertrag simuliert. Nach dem Marginalprinzip wurden aus diesen Ertrags-Aufwandsbeziehungen die Höhen der gewinnmaximalen Stickstoffgaben für jeden Teilschlag (20x20 Meter) ermittelt und appliziert. Die abgebildeten Zusammenhänge des Neuronalen Netzes bleiben verborgen und haben den Charakter einer Black Box. Jedoch lassen sich Entscheidungsstrukturen ex post anhand der gewinnmaximalen Stickstoffdüngung mithilfe von Entscheidungsbaumalgorithmen sichtbar machen (Abbildung 3 und 4).

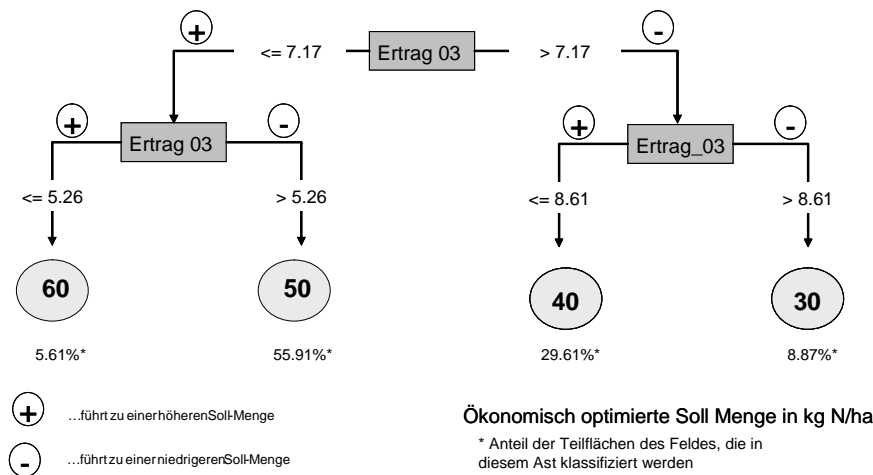


Abbildung 3: Verkürzter Entscheidungsbaum zur ersten Stickstoffgabe

Anzumerken ist, dass die in den Abbildungen gezeigten Entscheidungsbäume verkürzt dargestellt sind, wodurch die tatsächlich umgesetzte Präzision vermeintlich herabgesetzt wird. Die vollständigen Entscheidungsbäume enthalten 9 bzw. 13 Ebenen und nicht 2 bzw. 3, wie hier. Dadurch ist die Übersichtlichkeit und Interpretierbarkeit eines vollständigen Baumes auch nur eingeschränkt möglich. Aus den hier dargestellten Entscheidungsbäumen ergeben sich nur grobe Unterteilungen.

Auffällig ist zur ersten Gabe der „inverse Mappingansatz“. Das bedeutet, dass auf den Teilflächen eine erhöhte Stickstoffgabe appliziert wird, auf denen in der Vergangenheit nur niedrige Ertragsniveaus erreicht wurden. Umgekehrt verhält es sich mit Zonen, in denen historisch höhere Erträge kartiert wurden. Im Entscheidungsbaum führen diese Merkmalsausprägungen zu niedrigeren Stickstoffgaben.

Die Entscheidungsstruktur zur zweiten Stickstoffgabe (Abbildung 4) lässt einen starken Einfluss des aktuell ermittelten Stickstoffversorgungsindikators REIP_32 erkennen. Teilflächen mit niedrigerem REIP_32 erhalten tendenziell eine höhere Stickstoffmenge. Auch andere Attribute, wie beispielsweise die EC-Messung, beeinflussen in den vollständigen Bäumen die Entscheidungsfindung. Sie sind hier jedoch aus Gründen der bereits erwähnten vereinfachten Darstellung nicht eingezeichnet.

Die Entscheidungsstruktur zur dritten Stickstoffgabe verläuft nach ähnlichem Muster. Einen starken Einfluss hat hier die Merkmalsausprägung der REIP_49 Messung.

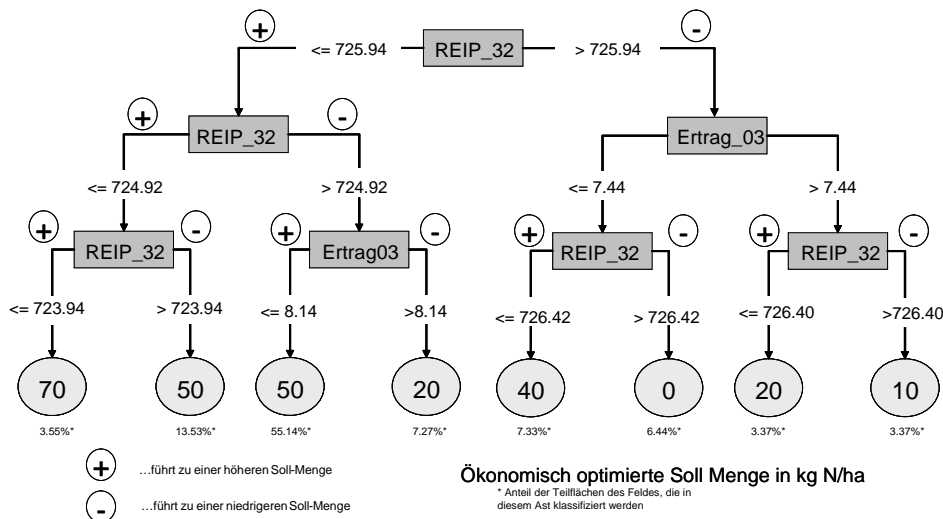


Abbildung 4: Entscheidungsbaum zur zweiten Stickstoffgabe

Die scheinbare Homogenität des Standortes, die schon bei der Einteilung der drei Ertragszonen des Versuchsgliedes „Injektor“ auffällig war, tritt hier auch wieder in Erscheinung.

Zur ersten Stickstoffgabe entfallen 85 Prozent der Gesamtfläche des Schläges auf zwei Äste des Entscheidungsbaumes wozu die Düngeempfehlung zwischen 40 und 50 kg N/ha liegt. Zur zweiten Stickstoffgabe variiert die empfohlene Gesamtmenge etwas stärker (0 bis 70 kg N/ha).

Die Tabelle 1 fasst die einzelnen Teilgaben zur Stickstoffdüngung über die unterschiedlichen Versuchsglieder zusammen. Auffällig ist das im Vergleich zu den anderen Versuchsgliedern insgesamt niedrige Düngenniveau des Versuchsgliedes „Netz“. Knapp 30 kg N/ha wurden hier im Durchschnitt im Vergleich zur flächeneinheitlichen Düngemethode „Betrieb“ weniger appliziert. Die Düngung wurde zu den Versuchsgliedern „Betrieb“, „Sensor“ und „Netz“ in Form von Kalkammonsalpeter (KAS) mit einem Schleuderdüngerstreuer durchgeführt. Zur Depotinjektionsdüngung wurde eine NTS Lösung (27% Stickstoff, 3% Schwefel) direkt in den Boden injiziert.

Versuchsglied	Fläche ha	1. Gabe		2. Gabe		3. Gabe		gesamt
		Menge (kg/ha)	Streuung (kg/ha)	Menge (kg/ha)	Streuung (kg/ha)	Menge (kg/ha)	Streuung (kg/ha)	Menge (kg/ha)
„Betrieb“	8,4	55	0	60	0	60	0	175
„Sensor“	11,1	55	0	61	44 – 80	66	53 – 80	182
„Injektor“	14,3	190	165 – 220					190
„Netz“	10,6	44	30 – 60	47	10 – 60	57	30 – 70	148

Tabelle 1: Stickstoffapplikationsmengen der einzelnen Versuchsglieder

4 Ergebnis

In Tabelle 2 sind die Ergebnisse des Feldversuches enthalten. Den höchsten Naturalertrag erreicht trotz durchschnittlich niedrigstem Düngenniveau das Versuchsglied „Netz“ mit 76,8 dt/ha. Damit übertrifft es die flächeneinheitliche Vergleichsvariante „Betrieb“ um 6,4 dt/ha. Den höchsten Proteingehalt erreicht das Versuchsglied „Injektor“. Hier wurde auch durchschnittlich die höchste Menge Stickstoff pro Hektar eingesetzt. Zur ökonomischen Bewertung der unterschiedlichen Düngestrategien muss die

um die Gesamtkosten der Stickstoffdüngung reduzierte Leistung (NDKL) herangezogen werden. Als Kalkulationsgrundlage der Kosten wurde ein für diese Region möglicher 2.000 Hektarbetrieb mit einem Getreideanteil von 65 Prozent (entspricht: 1.300 ha) angenommen. Weiterhin wurde angenommen, dass der Yara-N-Sensor© jährlich auf dieser Fläche eingesetzt wird und die Depotinjektionsdüngung durch einen Dienstleister im Lohn mit entsprechender Technik durchgeführt wird.

	„Betrieb“	„Sesor“	„Injetor“	„Netz“
Stickstoffgabe (kg/ha)	175	182	190	148
Ertrag (dt/ha)	70,4	73,4	72,1	76,8
Proteingehalt (RP in TS, %)	14,3	14,9	15,4	12,9
NKL* (€/ha)	606	633	615	647
NDKL** (€/ha)	591	613	585	628
* stickstoffkostenfreie Leistung, berechnet unter Berücksichtigung des Proteingehaltes, Annahme: Verkauf ab Feld ** stickstoff- und stickstoffdüngungskostenfreie Leistung, berechnet unter Berücksichtigung des Proteingehaltes nach KTBL „Betriebsplanung Landwirtschaft 2004/05“, Arbeitsgang Düngerstreuen ab Feldrand, Düngerzufuhr Hof-Feld; Yara®-Sensoreinsatz zu Versuchsglied „Sensor“ und „Netz“, Annahme: Einsatz auf jährlich 1300 ha, AfA 5 Jahre, Zinssatz 8% p.a.				

Tabelle 2: Ergebnisse des Feldversuches

Bei der monetären Bewertung des Naturalertrages wurde der Proteingehalt mit den für die Region Halle (Saale) möglichen Auszahlungspreisen (Stand: August 2005) berücksichtigt. Für den Verkauf ab Feld wurden 95 €/t (bis 13% Proteingehalt) und 100 €/t (über 13% Proteingehalt) erzielt. Zur Kalkulation der Kosten für den Schleuderdüngerstreuer, fanden die Vollkosten Berücksichtigung. Es wurden die fixen- und variablen Kosten für den Traktor mit Streuer, die Kosten für Dieseltreibstoff und Arbeitszeit der Arbeitsgänge „Streuen ab Feldrand (24m AB)“ und „Düngertransport zum Feld“ (KTBL 2004, S. 86/87) einbezogen. Zur Berechnung der Kosten des Yara-N-Sensors® (Versuchsglied „Sensor“ und „Netz“) wurde angenommen, dass der Betrieb ein eigenes Gerät anschafft und über einen Zeitraum von 5 Jahre abschreibt (8% Zinsen).

Die Kosten pro Hektar für den Dünger und die Ausbringung zum Versuchsglied „Injektor“ orientieren sich am Angebot eines Lohnunternehmers (Annahme: Applikation von 190 kg N/ha).

Trotz niedrigstem Proteingehalt übertrifft die Düngemethode „Netz“ mit 37 €/ha NDKL die schlageneinheitliche Vergleichsvariante. Der Online Ansatz des Sensors erreicht eine höhere NDKL von 22 €/ha bezogen auf das Versuchsglied „Betrieb“. Der Depotinjektionsdüngung kamen unter den Voraussetzungen des Versuchsjahres auf diesem Standort mit einem Verlust von 6 €/ha (Vergleich: schlageneinheitliche Düngung) keine ökonomischen Vorteile zu.

Zur Auswertung des Versuches wurde ein Mittelwertvergleich der Ertragsergebnisse zwischen den Versuchsgliedern durchgeführt. Trotz des Ansatzes der Streifeneinteilung nach annähernd identischen historischen Ertragsdurchschnitten und Leitfähigkeitswerten (siehe 3.1) ist nicht sicher gewährleistet, dass evtl. ein Versuchsglied nicht gegenüber einem anderen auf begünstigten Standorten durchgeführt wurde. Ein solcher Fall würde die Aussage des Mittelwertvergleiches einschränken.

Tabelle 3 zeigt die Ertragsmittelwerte der unterschiedlichen Versuchsglieder nach einem möglichen Indikator der Bodengüte. Dazu wurden die Werte der scheinbaren elektrischen Leitfähigkeit für diesen Schlag in 5 Klassen unterteilt (equal count). Für jede Klasse ist der Ertragsmittelwert des entsprechenden Versuchsgliedes angegeben.

	Klasse 1	Klasse 2	Klasse 3	Klasse 4	Klasse 5
EC in mS/m	23,1–25,79	25,80–26,47	26,48–26,94	26,95–27,67	27,68–36,69
„Betrieb“ (t/ha)	7,20	6,84	6,87	7,01	7,32
„Sensor“ (t/ha)	7,16	7,43	7,53	7,39	7,30
„Injektor“ (t/ha)	7,24	7,11	7,15	7,27	7,33
„Netz“ (t/ha)	7,83	7,74	7,50	7,52	7,71

Tabelle 3: Ertrag nach EC Klassifizierung

Deutlich wird auch hier der durchschnittliche Ertragsvorteil des Versuchsgliedes „Netz“ gegenüber den Vergleichsgliedern. Zusammen mit der oben angesprochenen gleichmäßigen Verteilung der Versuchsglieder über den Schlag nach Maßgabe annähernd identischer historischer Ertragsdurchschnitte und Leitfähigkeitswerte, untermauert dies die gefundenen Ergebnisse bezüglich der ökonomischen Vorzüglichkeit der Varianten.

5 Schlussfolgerung

Allen vier Versuchsgliedern lagen Entscheidungsregeln zugrunde, wonach die Stickstoffapplikation geplant wurde. Zum Versuchsglied „Betrieb“ sind diese Regeln nicht vollständig reproduzierbar, da hier „Gefühl- bzw. Bauchentscheidungen“ des Entscheidungsträgers eine Rolle spielen. Die Entscheidungsregeln der Versuchsglieder „Sensor“, „Injektor“ und „Netz“ sind reproduzierbar. Jedoch ist bei den beiden ersten Methoden das Ziel, die Erntemengen und nicht den Gewinn zu maximieren.

Eine methodisch schlüssige Herangehensweise zur Maximierung des Gewinns auf Teilflächen in Verbindung mit reproduzierbaren Entscheidungsregeln findet sich im Versuchsglied „Netz“.

In diesem Feldversuch hat sich gezeigt, dass diejenigen Entscheidungsregeln zum besten Ergebnis geführt haben, welchen die größte Informationsdichte zugrunde lag.

Allerdings sind diese Regeln sehr komplex. Künstliche Neuronale Netze scheinen eine Möglichkeit zu bieten, trotz dieser Komplexität die Zusammenhänge zwischen Input- und Outputparametern herauszufinden. Sie lassen sich dann mithilfe von Entscheidungsbaumalgorithmen darstellen und analysieren.

Vorgestellt wurde das Ergebnis eines einzigen Feldversuches. Das Ergebnis ist absolut ermutigend, jedoch wird zu überprüfen sein, inwieweit die hier präsentierten Ergebnisse wiederholbar sind.

Zukünftig ist denkbar, aus einer Vielzahl von räumlich hoch aufgelösten Standortinformationen für eine Region, allgemeingültige Entscheidungsregeln zu erstellen.

In jedem Fall ist der Wert hervorzuheben, der teilflächenbezogenen Daten zukommt. Hier wird er direkt monetär bewertbar.

Literatur:

BAETGE, J. und UTHOFF, C. (1998): Entwicklung eines Bonitätsindex auf der Basis von Wirtschaftsauskünften der Vereine Creditreform mit Künstlichen Neuronalen Netzen. IN: NAKHAEIZADEH, G. (Hrsg.): Data Mining, S. 289 - 308.

BLACKMORE, GODWIN und FOUNTAS (2003): The Analysis of Spatial and Temporal Trends in Yield Map Data over Six Years. IN: Biosystems Engineering, (2003) 84(4), S. 455-466.

CALLAN, R. (2003): Neuronale Netze, München 2003.

CHAUDHARY, A., COLVING, T.S., JAYNES, D.B., KASPAR, T.C.(2005): Development of Nitrogen Response Curves Using Field Scale Data and Data Mining. IN: Proceedings of the 7th International Conference on PF, 2004, pdf S. 1491-1503

DIKER, K., HEERMANN, D.F., BUCHLEITER, G.W., BAUSCH, W.C., FARAHANI, H. und WESTFALL, D. (2005): Modelling Yield By Neuronal Networks. IN: Proceedings of the 7th International Conference on PF, 2004, pdf S. 1997-2004, Minneapolis.

ISENSEE, E., THIESSEN, E., und ENGELN, P. (2000): Technik der Stickstoffdüngung in der Teilflächenbewirtschaftung. Institut für Landwirtschaftliche Verfahrenstechnik (unveröff. Manuskript).

HOSKINSON, R. L., HESS, J. R. und FINK, R. K. (1999): A Decision Support System for Optimum use of Fertilizers. IN: In: STAFFORD, J. V. (Ed.): Proceedings of the 2nd European Conference on Precision Agriculture '99, S. 907 - 916, Odensee.

HUANG, X., KRAVCHENKO, A. und THELEN, K. (2005): Yield Variability in Undulating Fields: Classification and Prediction. IN: Proceedings of the 7th International Conference on Precision Agriculture, 2004, pdf S.419-431, Minneapolis.

KITCHEN, N. R., DRUMMOND, S. T., LUND, E. D., SUDDUTH, K. A. und BUCHLEITER, G. W. (2003): Soil Electrical Conductivity and Topography Related to Yield for Three Contrasting Soil-Crop Systems: IN: Agronomy Journal 95, S. 483-495.

KOLLIG, M. (1993): Entscheidungshilfen für den Zuckerrübenanbau - Entscheidungsunterstützungsmodule für den Zuckerrübenanbau mittels neuronaler Netze und regelbasierter Systeme - Agrarwirtschaft Sonderh.138, Gießen.

KTBL (Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V.) 2004: Betriebsplanung Landwirtschaft. Darmstadt, 2004

LISSO, H. (2003): GPS-gestützte Teilflächenbewirtschaftung. RKL-Schrift 4.1.0, S. 1123-1143.

LINK, A., PANITZKI, M. und REUSCH, S. (2002): Hydro N-Sensor: Tractor-Mounted Sensing für Variable N Fertilization. IN: Proceedings of the 6th International Conference on Precision Agriculture, Minneapolis, S. 1012-1018, Minneapolis (2002).

LOWENBERG-DeBOER, J. (1996): Precision Farming and the New Information Technology: Implications for Farm Management, Policy, and Research: Discussion. IN: American Journal of Agricultural Economics 78, S. 1281 - 1284.

LUND, E. D., CHRISTY, C. D. und DRUMMOND, P. E. (1999): Practical Applications of Soil Electrical Conductivity Mapping. IN: STAFFORD, J. V.(Ed.): Proceedings of the 2nd European Conference on Precision Agriculture '99, S. 771 - 779, Odensee.

NAKHAIEZADEH, G., REINARTZ, T. und WIRTH, R. (1998): Wissensentdeckung in Datenbanken und Data Mining: Ein Überblick. IN: NAKHAIEZADEH, G. (Hrsg.): Data Mining, S. 1 - 33.

PETERS, M. W. et al. (1999): Nitrogen Management Strategies for Precision Farming. IN: STAFFORD, J. V. (Ed.): Proceedings of the 2nd European Conference on Precision Agriculture '99, S. 719 - 728, Odensee.

SOMMER, K. (2003): Grundlagen des „CULTAN“-Verfahrens. IN: KÜCKE, M. (Hrsg.): Anbauerfahrungen mit N-Injektion (CULTAN) – Ergebnisse, Perspektiven , Erfahrungen. FAL Sonderheft 25.

WEIGERT, G. (2006): Data Mining und Wissensentdeckung im Precision Farming -Entwicklung von ökonomisch optimierten Entscheidungsregeln zur kleinräumigen Stickstoff-Ausbringung, Dissertation, Weihenstephan (im Druck)

WELSH, J. P. et al. (1999): Developing Strategies for Spatially Variable Nitrogen Application. IN: STAFFORD, J. V. (Ed.): Proceedings of the 2nd European Conference on Precision Agriculture '99, S. 729 - 738, Odensee.

WENKEL, K. O. et al. (2001): Development and Evaluation of different Methods for Site-Specific Nitrogen Fertilization of Winter Wheat. IN: GRENIER, G. und BLACKMORE, S. (Ed.): Third European Conference on Precision Agriculture, S. 743 - 745.

WENKEL, K. O. et al. (2004): Düngung. In: KTBL, Managementsystem für ortsspezifischen Pflanzenbau, Ergebnisbericht pre agro (CD-ROM), 2004, Kapitel 4. S.151-284.

Kurzfassung

Entscheidungsregeln bilden die Grundlage für eine erfolgreiche und nachhaltige Landbewirtschaftung. Mithilfe dieser Regeln wird die Frage beantwortet, welche Handlungsalternativen unter bestimmten Bedingungen ausgewählt werden.

Auf der Grundlage von Ertragsprognosen durch künstliche Neuronale Netze wird eine Herangehensweise vorgestellt, wodurch diese Entscheidungsregeln für die teilflächenspezifische Stickstoffdüngung automatisch generiert werden können. Innerhalb eines Feldversuches wurde die Stickstoffdüngung zu Winterweizen nach automatisch erstellten Entscheidungsregeln mit anderen Düngemethoden verglichen. Unter ökonomischen Gesichtspunkten erreicht die Düngung nach automatisch generierten Entscheidungsregeln das beste Ergebnis.

Stichworte

Entscheidungsregeln, Data Mining, Künstliche Neuronale Netze, Precision Farming, Stickstoffdüngung

Summary

The basis for a successful and sustainable agriculture is the utilization of adequate decision rules. These rules determine the actions to be taken.

For the site specific nitrogen fertilization a method is presented to automatically establish decision rules based on yield predicting artificial neuronal networks.

These rules were used at a field trial with winter wheat and compared with other fertilization strategies. On an economical point of view, these automatically generated decision rules reached the best result.

Keywords

Decision rules, Data Mining, Artificial Neuronal Networks, Precision Farming, Nitrogen Fertilization

Danksagung

Die Entwicklung von Entscheidungsregeln zur variablen Stickstoffdüngung war Teil des DFG (Deutsche Forschungsgemeinschaft) Projektes „IKB Dürnast“ (FOR 473).

Autoren

Prof. Dr. Peter Wagner
Martin-Luther-Universität Halle-Wittenberg
Professur für landwirtschaftliche Betriebslehre
06099 Halle
Tel.: 0345/5522360, Fax: 0345/5527109
E-Mail: peter.wagner@landw.uni-halle.de

Dipl.-Ing. agr. Martin Schneider
Martin-Luther-Universität Halle-Wittenberg
Professur für landwirtschaftliche Betriebslehre
06099 Halle
Tel.: 0345/5522374, Fax: 0345/5527109
E-Mail: martin.schneider@landw.uni-halle.de

Dipl. Kfm. Georg Weigert
TU München Weihenstephan
Professur für Unternehmensforschung und Informationsmanagement
Alte Akademie 14
85350 Freising
Tel.: 08161/71-3576, Fax: 08161/71-3408
E-Mail: Georg.Weigert@wzw.tum.de