

Verarbeitung großer Datenmengen mittels Neuronaler Netze zur Schätzung kleinräumiger Produktionsfunktionen

Peter Wagner, Martin Schneider

Professur für landwirtschaftliche Betriebslehre
Universität Halle
06099 Halle/Saale
peter.wagner@landw.uni-halle.de
martin.schneider@landw.uni-halle.de

Abstract: Es wird eine Methode vorgestellt, wodurch mithilfe von künstlichen Neuronalen Netzen Erträge prognostiziert werden um kleinräumige Produktionsfunktionen für jede einzelne Stickstoffteilgabe zu schätzen. Auf Grundlage von Feldversuchen zur Stickstoffdüngung von Winterweizen wird die Güte der Ertragsprognose untersucht.

1 Einleitung

Für fundierte Düngeentscheidungen ist es notwendig, den Verlauf der Produktionsfunktion zu kennen. Langjährige Erfahrungen mit Faktorsteigerungsversuchen liegen vor, ohne bisher zu einem abschließenden Ergebnis gekommen zu sein. Es ist festzustellen, dass diese Art von empirisch ermittelten Produktionsfunktionen oftmals keine Gültigkeit für andere Standorte hat (räumlich) und dass in der Abfolge von Jahren die Formen dieser Produktionsfunktionen für einen Standort voneinander abweichen (zeitlich). Die räumliche Abweichung dieser Produktionsfunktionen findet Begründung in den unterschiedlichen Standortbedingungen. Oftmals werden auch nur wenige/nicht alle standortcharakterisierende Merkmale in die Schätzung der Funktionen mit einbezogen. Die zeitliche Abweichung der Form der Produktionsfunktionen kann durch unterschiedliche Witterungsbedingungen der einzelnen Jahre begründet werden. Dabei ist gerade in Regionen mit Wasser als wachstumslimitierendem Faktor neben der Niederschlagssumme über die Zeit auch die Verteilung über die Wachstumsperiode von eminenter Bedeutung. Auf die zeitliche Verteilung der Niederschläge kann durch Höhe und Zeitpunkt der einzelnen Gaben reagiert werden. Oftmals wird dieser Umstand vernachlässigt, indem in der Produktionsfunktion nur die gesamte Düngermenge berücksichtigt wird. Eine Einzelbetrachtung jeder Teilgabe kann nur mit erheblichem Mehraufwand technisch umgesetzt werden. Jedoch liegt sicherlich in der Aufteilung der Gesamtmenge über die Teilgaben noch ein erheblicher Optimierungsspielraum. Zusätzlich stellt bei der Bewirtschaftung die Differenzierung nach kleinräumigen Standortunterschieden eine weitere Erhöhung der Komplexität dar. In diesem Fall sind angepasste Produktionsfunktionen für jede Teilfläche notwendig. Bisherige praktizierte Konzepte bei der teilflächenspezifischen Stickstoffdüngung beruhen entweder nur auf reinen Sensoransätzen oder nur auf

reinen Kartenansätzen. Dabei wird entweder ausschließlich die aktuelle Bestandessituation als Entscheidungskriterium für die Applikationshöhe oder andererseits nur die Einteilung nach Ertragspotenzialzonen genutzt. Bei ersterem wird also das mögliche Ertragspotenzial einer Teilfläche, bei letzterem die bisherige Bestandesentwicklung, vollkommen ausgeblendet. Aber beispielsweise durch unterschiedliche Witterungsverläufe der einzelnen Jahre, ist die Kombination dieser beiden Konzepte empfehlenswert. Je mehr Informationen der Entscheidung zugrunde liegen, desto sicherer kann sie getroffen werden.

In diesem Beitrag wird ein Konzept vorgestellt, womit unter der Nutzung von vielfältigen teilflächenspezifischen Informationen mittels künstlicher Neuronaler Netze (kNN) kleinräumige Produktionsfunktionen geschätzt werden. In Feldversuchen wurden diese kleinräumigen Produktionsfunktionen angewendet. Die Prognosegüte der kNN wird untersucht.

2 Material und Methoden

Die Ermittlung der Ertrags- Aufwandsbeziehungen erfolgt über ein Ertragsprognosemodell. Dazu werden kNN genutzt. Mittels einer Datenbank werden zu den geernteten Erträgen auf einer Teilfläche eines Jahres die Bedingungen zugeordnet, die darauf herrschten. Dazu gehören erstens die natürlichen Voraussetzungen („Bodenattribute“) in Form von einer Messung der scheinbaren elektrischen Leitfähigkeit oder Vorjahreserträgen. Zweitens werden bestandesbeschreibende Parameter („In-Season Attribute“) aufgenommen, welche die Bestandesentwicklung zu den entscheidenden Zeitpunkten vor der 2. und 3. Stickstoffteilgabe auf der Teilfläche charakterisieren. Drittens wird die tatsächlich applizierte Stickstoffmenge jeder einzelnen Teilgabe der Teilfläche aufgenommen, die zu dem entsprechenden Ertrag führte. Mit diesem Datensatz wird für jede einzelne der drei Stickstoffteilgaben ein kNN trainiert. Dabei passt sich das Netz den Mustern an, die in dieser Datenbank vorhanden sind. Es „lernt“, welche Bedingungen auf den einzelnen Teilflächen zu welchen Erträgen geführt haben. Diese trainierten kNN können nun anschließend auf neue Teilflächen angewendet werden. Dabei prognostizieren sie die erwarteten Erträge zur vorgegebenen Teilflächencharakteristik unter Annahme einer Stickstoffmenge. Werden alle technisch realisierbaren Stickstoffhöhen mit diesem trainierten kNN angewendet, so lassen sich die Ertrags- und Aufwandsbeziehungen für jede Teilfläche darstellen. Das ökonomische Optimum der Stickstoffhöhe für jede einzelne Teilgabe kann bestimmt werden. Zur näheren Beschreibung der Methodik sei auf [We06] verwiesen.

Mit dem Datensatz eines Feldversuches zur Stickstoffdüngung des Jahres 2004 auf einem Schlag des Versuchsgutes „Domäne Görzig“ der Universität Halle, wurde für jede Teilgabe ein kNN trainiert. Auf diesem Schlag wurden neben unterschiedlichen Stickstoffdüngungsstrategien zu Winterweizen auch Stickstoffsteigerungspartellen mit Variationen in der Höhe und zwischen den einzelnen Teilgaben angelegt. Diese Steigerungspartellen sind notwendig, um den Merkmalsraum für die kNN auszuweiten. Vor der zweiten und dritten Teilgabe wurden zur Bestimmung der „In-Season Attribute“ Überfahrten mit dem Yara-N-Sensor im „Fieldscanmodus“ gemacht.

Daraus wurde der Red Edge Inflection Point (REIP) als bestandesbeschreibender Parameter bestimmt. Die trainierten kNN wurden im Erntejahr 2006 auf zwei weiteren Schlägen (131 und 330) der Domäne im Feldversuch angewendet. Dazu wurden Streifenversuche angelegt, worin die Düngestrategien „Netz“ (ökonomisch optimale N-Menge jeder Teilgabe), „Sensor“ (Yara-N-Sensor) und „Konstant“ (Empfehlung des Pflanzenbauleiters) zur Anwendung kamen. Auf dem Schlag 131 wurde nur nach den Strategien „Netz“ und „Konstant“ gedüngt. Auf beiden Schlägen wurden Teilflächen angelegt, die aufgrund der Arbeitsbreite des Düngerstreuers der kleinsten noch zu bewirtschaftenden Einheit entsprechen (24x24 m) und entlang der Fahrspuren ausgerichtet sind. In Abbildung 1 ist die Streifenteilung der Düngestrategien mit den Teilflächen enthalten. Zu jeder einzelnen Teilfläche ist der prognostizierte Ertrag zu jeder Teilgabe mit der tatsächlich geernteten Menge vorhanden.

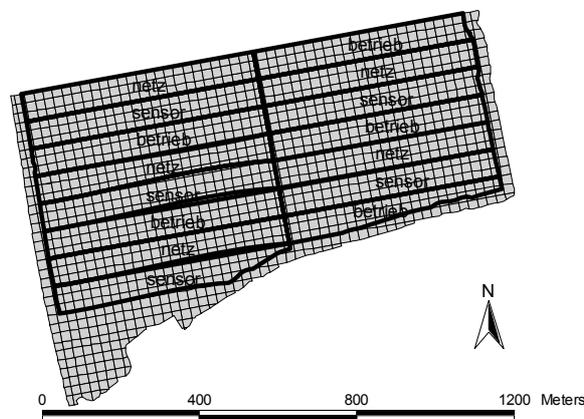


Abbildung 1: Versuchsdesign Schlag 330 mit Einteilung der Teilflächen

3 Ergebnisse und Auswertung

In Abbildung 2 werden die Korrelationen der prognostizierten Erträge vor jeder Teilgabe mit den tatsächlich geernteten Erträgen der beiden Schläge dargestellt. Als Input Parameter für die Prognose zur jeweiligen Teilgabe fließen die Bodenparameter, In-Season Parameter und die bisher prognostizierten und tatsächlich gedüngten N-Mengen („Netz“) bzw. die prognostizierten N-Mengen („Konstant“ und „Sensor“) ein. Dabei wird zusätzlich nach der Düngestrategie unterschieden. Ein Vergleich der absoluten Ertragsniveaus ist unzulässig, da zwischen Prognose und Ernte der nicht zu berücksichtigende Witterungseinfluss liegt. Absolut liegen die prognostizierten Erträge über dem tatsächlich geernteten Niveau. Für den Schlag 330 ergeben sich nur schlechte Korrelationen zwischen 0 und 0,25. Auf Grundlage von historischen Ertragskarten kann eine geringe Heterogenität für diesen Schlag festgestellt werden. Es könnte auch sein, dass dieser Schlag eine andere Charakteristik aufweist, als der Schlag, worauf der Trainingsdatensatz erstellt wurde. Anders ist dies für den Schlag 131. Hier liegt auch die Korrelation mit 0,58 bis 0,91 deutlich höher.

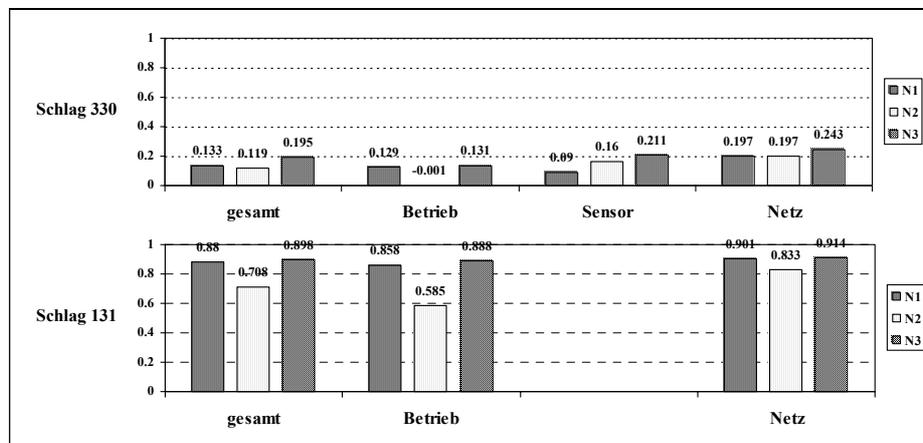


Abbildung 2: Korrelation der prognostizierten Erträge mit dem geernteten Ertrag

Bei beiden Schlägen ist zu erkennen, dass insgesamt die Prognosegüte von der ersten bis zur 3. Teilgabe ansteigt. Die zweite Gabe fällt im Vergleich zu den beiden anderen Gaben ab. Diese, im Vergleich zu den anderen Teilgaben, schlechtere Prognose kann ein Hinweis dafür sein, dass die Qualität des Trainings dieses kNN oder aber der Trainingsdatensatz für diese Gabe schlechter ist. Die Korrelation des prognostizierten mit dem geernteten Ertrag auf den Teilflächen, wo zusätzlich die ermittelten optimalen Stickstoffmengen auch tatsächlich appliziert wurden (Strategie „Netz“), ist im Vergleich zu den anderen Düngestrategien am höchsten.

4 Ausblick

Mit dieser Methode lassen sich teilflächenspezifische Düngentscheidungen unter Berücksichtigung von Bodenpotenzial und aktueller Bestandesentwicklung ermitteln. Es ist ohne weiteres möglich, weitere ertragsbeeinflussende Parameter mit aufzunehmen. Die Voraussetzung dafür ist, dass sie räumlich hoch aufgelöst vorliegen. Beispielsweise ist es denkbar, dass Geländemodelle oder Daten zur räumlichen Verteilung des pH-Wertes mit einfließen.

Weiterhin ist denkbar, dass die Qualität als zweites Zielattribut mit in das Modell aufgenommen wird. Damit wäre nicht nur eine Optimierung nach der Erntemasse sondern auch nach der Qualität des Erntegutes möglich. Erste Erfahrungen mit einem Proteinsensor konnten im Erntejahr 2006 auf den Versuchsflächen gemacht werden.

5 Literaturverzeichnis

- [We06] Weigert, G.: Data Mining und Wissensentdeckung im Precision Farming – Entwicklung von ökonomisch optimierten Entscheidungsregeln zur kleinräumigen Stickstoff Ausbringung. Dissertation, TU München, 2006.