

Bestimmung des Betriebsmodus landwirtschaftlicher Maschinen auf Basis von GNSS-Messwerten

Jernej Poteko¹, David Eder² und Patrick Ole Noack²

Abstract: Die Unterscheidung zwischen Straßen- und Feldmodus ist entscheidend für den sicheren, effizienten und bedarfsgerechten Betrieb von Landmaschinen. Der Betriebsmodus setzt die Rahmenbedingungen für die optimale Einstellung verschiedener Parameter u.a. des Reifendrucks. Die Identifikation des Betriebsmodus kann durch die Klassifizierung mittels Entscheidungsbäumen aus den Geschwindigkeits- und Fahrtrichtungsmesswerten von GNSS-Sensoren abgeleitet werden. Die vorliegenden Untersuchungen zur Erkennung von Straßen- und Feldmodus erreichten bei der Differenzierung der Testdaten eine Genauigkeit von 92 %. Aus dem hohen harmonischen Mittel (95 %) lässt sich die Zuverlässigkeit bei der Bestimmung des Betriebsmodus ableiten. Es ist von großer Bedeutung, dass die Anzahl der Fehlentscheidungen hinsichtlich der Erkennung des Betriebsmodus während der Straßenfahrt minimiert wird, da dort die Verkehrssicherheit eine wichtigere Rolle spielt als bei einer Entscheidung auf dem Feld.

Keywords: Betriebsmodus, Entscheidungsbaum, GNSS-Daten, Automatisierung, landwirtschaftliche Maschinen

1 Einleitung

Die Anforderungen an Landmaschinen sind vielfältig. Sie werden sowohl auf der Straße für den Transport und die Fahrt zum Feld als auch auf dem Feld selbst eingesetzt. Die optimale Einstellung von unterschiedlichen Funktionen der landwirtschaftlichen Maschinen hängt stark vom Betriebsmodus ab. Die Kenntnis der Betriebsmodi „Straßenfahrt“ und „Feldarbeit“ sind entscheidend für den sicheren, effizienten und bedarfsgerechten Betrieb von Landmaschinen und seine Dokumentation in *Farm-Management-Information-Systemen (FMIS)*. Die Unterscheidung zwischen Transportmodus und Feldarbeit stellt eine Grundlage für die Automatisierung und Optimierung von Arbeitsprozessen dar [KGP17].

Die Rolle des Reifendrucks wurde in den letzten Jahrzehnten intensiv untersucht. Ein niedriger Reifendruck während der Feldfahrt wirkt sich durch die Verringerung des Kraftstoffverbrauchs und eine geringere Bodenverdichtung positiv aus. Andererseits verringert ein hoher Reifendruck bei Straßenfahrt den Rollwiderstand und damit den Kraftstoffverbrauch. Er trägt auch zu einem stabilen und damit sicheren Fahrverhalten bei.

¹ Hochschule Weihenstephan-Triesdorf, Biomasseinstitut, 91746 Weidenbach, Deutschland,
jernej.poteko@hswt.de

² Hochschule Weihenstephan-Triesdorf, Fakultät Landwirtschaft, Lebensmittel und Ernährung, 91746 Weidenbach, Deutschland, david.eder@hswt.de; patrick.noack@hswt.de

Mit Reifendruckregelanlagen kann der Druck im Reifen in Abhängigkeit vom Betriebsmodus angepasst werden. Die Anpassung erfolgt dabei in der Regel manuell durch den Fahrer. Eine automatische Anpassung des erforderlichen Reifendrucks wäre von Vorteil, um den Fahrer zu entlasten und Fehlbedienungen durch wenig geschultes Personal zu vermeiden. Dies setzt voraus, dass die Reifendruckregelanlage den Betriebsmodus ermitteln kann.

Die vorliegende Studie untersucht, ob die Identifikation des Betriebsmodus durch Klassifizierung mittels Entscheidungsbäumen aus den Daten von GNSS-Empfängern abgeleitet werden kann. Die naheliegende Verknüpfung bekannter Feldgrenzen und der GNSS-Positionsdaten wurde nicht verfolgt, da die Flexibilität des Systems dann durch die Verfügbarkeit von Feldgrenzen eingeschränkt wird. Der vorgestellte Ansatz nutzt ausschließlich die Messgrößen Geschwindigkeit, Fahrtrichtung sowie aus diesen Größen abgeleitete Werte wie Beschleunigung und Winkelgeschwindigkeit. Eine ähnliche Untersuchung zeigte vielversprechende Ergebnisse zur Klassifizierung von Feld- und Transportprozessen anhand verschiedener aus GNSS-Daten extrahierter Parameter [SM18].

2 Material und Methoden

2.1 Daten

Die GNSS-Daten wurden am 6. April 2017 mit einem Traktor erfasst. Die Route enthält Straßen- und Feldfahrten in der Umgebung der Hochschule Weihenstephan-Triesdorf in Weidenbach, Deutschland (N 49.20270°, E 10.65233°; EPSG 4326). Somit spiegeln die Daten den Transport auf der Straße und die Ausbringung von Pflanzenschutz- oder Düngemitteln mit einer Arbeitsbreite von 21 m im Feld wider. Die Arbeitsgeschwindigkeit auf dem Feld betrug im Mittel 7,2 km/h. Auf dem Traktor wurde ein Trimble FMX-Display mit Ag25 Antenne (Trimble, California, USA) unter Verwendung von RTK-Korrekturdaten von SAPOS (Hannover, Deutschland) eingesetzt. Zeit, Geschwindigkeit und Richtung wurden mit einer Abtastrate von 5 Hz aufgezeichnet. Mit Hilfe der Positionsmessungen des GNSS-Empfängers und der Feldgrenzen wurde der Betriebsmodus referenziert.

2.2 Datenaufbereitung

Die Geschwindigkeit wurde ohne weitere Bearbeitung in die Analyse einbezogen. Weiterhin wurden aus der Geschwindigkeit, der Zeit und dem Kurs (Fahrtrichtung) zusätzliche Parameter abgeleitet (Tabelle 1) und in Microsoft Excel 2016 berechnet.

Sensor	Messprinzip	Messwert	Eingabewert	Statistische Kennzahl	Zeitraum
GNSS (Global Navigation Satellite System)	Dopplerverschiebung	Geschwindigkeit	Geschwindigkeit	Aktueller Wert	jetzt
				Median	1 s 20 s
				SD	1 s 20 s
			Beschleunigung	Aktueller Wert	jetzt
				Median	1 s 20 s
				SD	1 s 20 s
		Fahrtrichtung	Winkelgeschwindigkeit	Aktueller Wert	jetzt
				Median	1 s 20 s
				SD	1 s 20 s
			Winkelbeschleunigung	Aktueller Wert	jetzt
				Median	1 s 20 s
				SD	1 s 20 s
	Winkeldifferenz	Aktueller Wert	jetzt		
		Median	1 s 20 s		
		SD	1 s 20 s		
	Trilateration	Position	Abgleich mit Feldgrenzen als Referenz		
	Direkt	Zeit	Berechnung von Eingabewerten		

Tab. 1: Auf Geschwindigkeit, Zeit und Fahrtrichtung basierende Parameter, die bei der Entwicklung des Entscheidungsbaums verwendet wurden (SD - Standardabweichung)

Die Daten wurden zunächst gefiltert, um Werte außerhalb des erwarteten Bereichs (z. B. Geschwindigkeit über 60 km/h, Beschleunigung über 10 m/s²) auszuschließen. Die Referenz für die Betriebsmodi wurde durch den Vergleich der Position des Traktors mit den Feldgrenzen der untersuchten Felder mit der GIS-Software QGIS [QU19] festgelegt.

2.3 Klassifizierungsalgorithmus

Der *Machine-Learning*-Algorithmus klassifizierte die Daten je nach Regelausdruck in jedem Knoten in die Baumstruktur. Die Klassifikation strebte an, die Trennung der Daten zu maximieren. Der Entscheidungsbaum leitet aus den Eingangsparametern (Tabelle 1) den Betriebsmodus ab. In jedem Knoten wurde der Betriebsmodus (Straßen- oder Feldmodus), die Wahrscheinlichkeit des angegebenen Betriebsmodus und der Anteil der Werte im Knoten berechnet. Die Fehlerrate wird mit dem Stutzen des Baumes anhand des Komplexitätsparameters minimiert, um so das optimale Verhältnis zwischen Baumkomplexität und Genauigkeit zu erreichen. Der Entscheidungsbaum wurde mit dem R-Paket *rpart* erstellt [TAR15]. Die Identifizierung erfolgte mit dem R-Paket *predict*. Zunächst wurde der Trainingsdatensatz bei der Herleitung von Klassen im Entscheidungsbaum und als Testdatensatz bei der Validierung verwendet. Die Beurteilung der Qualität der Ergebnisse erfolgte mittels 10-facher Kreuzvalidierung.

2.4 Beurteilung des Algorithmus

Die Beurteilung eines binären Klassifikators kann durch eine Wahrheitsmatrize erfolgen. Die „positiven“ Klassen bestimmen den Feldmodus und die „negativen“ Klassen den Straßenmodus. Die Begriffe „richtig“ und „falsch“ definieren die korrekten und falschen Ergebnisse aus dem Entscheidungsbaum. In dieser Studie wurden die richtig positiven und richtig negativen Klassen als gewünschte Klassen identifiziert. Im Falle von Fehlklassifikation wurden falsch negative Klassen gegenüber falsch positiven Klassen bevorzugt.

Wahrheitsmatrize		Errechnete Klassen (Betriebsmodus)	
		Feldarbeit	Straßenfahrt
Tatsächliche Klassen	Feldarbeit	Richtig positiv	Falsch negativ
	Straßenfahrt	Falsch positiv	Richtig negativ

Tab. 2: Wahrheitsmatrize zur Beurteilung der Qualität der Klassifizierung

Aus Sicht der Straßenverkehrssicherheit verringert die Identifikation von falsch negativen Klassen das Risiko und reduziert so potenzielle Schäden an Maschinen, Fahrern und anderen Verkehrsteilnehmern. Die Beurteilung anhand von Wahrheitsmatrizen können mit folgenden Eigenschaften gekennzeichnet werden: Genauigkeit (ACC), Präzision (PPV), Sensitivität (TPR), Spezifität (TNR) und *F1-Score* [LE17].

3 Ergebnisse

Der Datensatz enthielt 54711 Positionen. 72 % der Positionen lagen innerhalb der Feldgrenzen. Die entscheidenden Parameter, die im Entscheidungsbaum verwendet wurden, waren der Median der Geschwindigkeit der letzten 20 Sekunden, die momentane Geschwindigkeit, die Standardabweichung der Beschleunigung der letzten 20 Sekunden, die Winkelbeschleunigung der letzten Sekunde, die Winkelgeschwindigkeiten der letzten Sekunde und der letzten 20 Sekunden, die Standardabweichung der Geschwindigkeit der letzten 20 Sekunden (Abb. 1). Im ersten Knoten lag die Wahrscheinlichkeit des Straßen- bzw. Feldmodus bei 28 % bzw. 72 %. Die Komplexitätsparameter von 0.01 wurden beim vierzehnten Knoten festgelegt.




Abb. 1: Entscheidungsbaum für die Klassifizierung von Straßen- (S) und Feldmodus (F) anhand von GNSS-Parametern (v = momentane Geschwindigkeit [km/h], a = Beschleunigung [m/s²], ω = Winkelgeschwindigkeit [rad/s], α = Winkelbeschleunigung [rad/s²], Med = Median, SD = Standardabweichung, 1 = Werte der letzten Sekunde, 20 = Werte der letzten 20 Sekunden)

Innerhalb aller Daten (Straßen- und Feldfahrt zusammen) wurden 92 % (ACC) der Klassifikationen korrekt als richtig positiv (Feldfahrtmodus) und richtig negativ (Straßenmodus) identifiziert (Tab. 3). Der Feldmodus wurde während der tatsächlichen Straßenfahrt in nur 3 % der Fälle falsch erkannt (PPV ist 97 %). Während der tatsächlichen Straßenfahrt wurde der Straßenmodus in 91 % Fällen (TNR) auch richtig errechnet. Innerhalb der tatsächlichen Feldfahrt wurde der Feldmodus in 92 % (TPR) richtig erkannt. Entsprechend hoch bei 95 % lag der *FI-Score* als harmonisches Mittel der Präzision und der Sensitivität.

		Errechnete Klassen (Betriebsmodus)	
		Positive	Negative
Tatsächliche Klassen	Positive	37987	3110
	Negative	1252	12362

Tab. 3: Wahrheitsmatrize mit angeordneten Klassen zur Beurteilung der Qualität des Entscheidungsbaums Klassifizierungsalgorithmus anhand von Testdatensätzen

4 Diskussion

Der aus den Trainingsdaten abgeleitete Entscheidungsbaum zeigte überzeugende Ergebnisse bei der Erkennung von Straßenfahrt und Feldarbeit. Er erreichte bei der Differenzierung von Straßen- und Feldmodus anhand der Testdaten eine hohe Güte. Dies

lässt sich durch die Genauigkeit und den *F1-Score* belegen. Beide Maße lagen bei 92 % und 95 % und überstiegen die Genauigkeiten (ca. 83 %) der Unterscheidungen zwischen der Feldarbeit und der Straßenfahrt aus einer vergleichbaren Untersuchung [SM18]. Aus der hohen Spezifität und Sensitivität lässt sich ableiten, dass falsche Vorhersagen von Feldmodus auf der Straße unter 10 % lagen. Es ist von großer Bedeutung, dass die Anzahl der Fehlentscheidungen hinsichtlich der Erkennung des Betriebsmodus während der Straßenfahrt minimiert wird, da dort die Verkehrssicherheit eine wichtige Rolle spielt und die Folgen einer Fehlentscheidung ein größeres Risiko bergen als bei einer Fehlentscheidung auf dem Feld. Die ersten Ergebnisse zeigen das Potenzial der Methode und können als Hinweis für die ausreichende Genauigkeit von Entscheidungsbäumen zur Erkennung des Betriebsmodus von Landmaschinen gewertet werden. Die vorgestellte Methode kann leicht auf andere Anwendungen und Einstellungen übertragen werden, bei denen die Kenntnis des Betriebsmodus relevant ist.

5 Danksagung

Die Studie wurde vom Bundesministerium für Wirtschaft und Energie der Bundesrepublik Deutschland im Rahmen des Förderungsprogramms „Zentrales Innovationsprogramm Mittelstand“ finanziell unterstützt.

Literaturverzeichnis

- [KGP17] Kortenbruck, D.; Griepentrog, H. W.; Paraforos, D. S.: Machine operation profiles generated from ISO 11783 communication data. *Computers and Electronics in Agriculture*, 140. 227-236, 2017.
- [Le17] Leonard, L. C.: Web-Based Behavioral Modeling for Continuous User Authentication (CUA). *Advances in Computers* 105 S. 1-44, 2017.
- [Qu19] Quantum, G. I. S.: QGIS Geographic Information System. Open Source Geospatial Foundation Project. Development Team 2014. 2019.
- [SM18] Stein, T.; Meyer, H. J.: Automatic machine and implement identification of an agricultural process using machine learning to optimize farm management information systems. In: *Proceedings of the 6th Int. Conf. on Machine Control and Guidance (MCG)*. Technische Universität Braunschweig, Germany, S. 19-26, 2018.
- [TAR15] Therneau, T.; Atkinson, B.; Ripley, B.: *rpart: Recursive Partitioning and Regression Trees*. R package version 4.1-11. <https://CRAN.R-project.org/package=rpart>, Stand: 5.8.2019.