

A. Ruckelshausen et al. (Hrsg.): Intelligente Systeme - Stand der Technik und neue Möglichkeiten,
Lecture Notes in Informatics (LNI), Gesellschaft für Informatik, Bonn 2016 15

Evidenzkarten-basierte Sensorfusion zur Umfelderkennung und Interpretation in der Ernte

Timo Korthals¹, Andreas Skiba², Thilo Krause², Thorsten Jungeblut¹

Abstract: Unser Ansatz zur Umfelderkennung in der Ernte basiert auf den Arbeiten zu Evidenzkarten von Elfes und Moravec. In einfacher Form kommen Evidenzkarten als „Occupancy Grid Maps“ in der Roboternavigation und Kollisionsvermeidung zur Anwendung. Sie stellen auf Grund der effizienten Verarbeit- und Interpretierbarkeit noch immer den Stand der Technik für aktuelle, autonome Roboter- und Automobilsysteme dar. Die Ansätze aus der Robotik nutzen wir im Rahmen unserer Arbeit und erweitern diese zur Anwendung in der Erntesituation, indem einzelne Karten die Wahrscheinlichkeit einer Eigenschaft des Umfeldes der Erntemaschine (Masten, Gräben, große Steine etc.) repräsentieren.

Keywords: Evidenzkarten, Sensorfusion, Umfelderkennung, Kartografierung

1 Einleitung

Erntemaschinen bewegen sich als komplexe, mobile Verarbeitungseinheiten biologischer Produkte in einem ständig wechselnden, unstrukturierten Umfeld. Sowohl für die Absicherung des Interaktionsraumes der Maschine als auch zur Steigerung der internen Prozessabläufe ist eine automatisierte Erkennung des Umfelds von großer Bedeutung.

Hindernisse vor dem Schneidwerk oder Implement sind oft durch das Erntegut verdeckt und stellen ein Gefahrenpotenzial dar. Bei Kollisionen muss mit Schäden an Mensch und Tier gerechnet werden, weiterhin kann es durch Schäden an Maschinen zu teuren Ausfallzeiten kommen. Hierbei ist zwischen stationären (Masten, Gräben, große Steine, etc.) und beweglichen (Menschen, Tiere, Maschinen, etc.) Hindernissen zu unterscheiden. Bedingt durch die Geometrie der Maschinen und die damit verbundene eingeschränkte Sicht auf das Umfeld, besteht bei Rangierfahrten oder Wendemanövern zusätzlich eine erhöhte Kollisionsgefahr. Eine intelligente Umfelderkennung hilft hier, Schäden zu verhindern. Diese Arbeit beschreibt unseren Ansatz zur Umfelderkennung in der Ernte, basierend auf den Arbeiten zu Evidenzkarten von Elfes und Moravec [E192].

¹ Universität Bielefeld, Kognitronik und Sensorik, Inspiration 1, 33619 Bielefeld,
{tkorthals, tj}@cit-ec.uni-bielefeld.de

² CLAAS Selbstfahrende Erntemaschinen GmbH, Münsterstr. 33, 33428 Harsewinkel,
{andreas.skiba, thilo.krause}@claas.com

2 Evidenzkarten im Ernteszenario

Eine Evidenzkarte ist ein Kartenstapel bestehend aus zweidimensionalen Gitterkarten, in denen die Umgebung der Erntemaschine äquidistant diskretisiert wird. Eine Karte innerhalb des Evidenzkartenstapels repräsentiert die Wahrscheinlichkeit der Anwesenheit einer einzelnen semantischen Eigenschaft (z.B. Hindernisse oder Bestandskanten) des Umfeldes der Erntemaschine [Ko15] (siehe

Abb. 1). Jeder diskreten Zelle m innerhalb der Karte wird ein kontinuierlicher Wahrscheinlichkeitswert $P(m)$ im Intervall $0 < P(m) < 1$ zugewiesen (siehe

Abb. 1). Dieser Wert gibt an, ob eine Eigenschaft dieser Zelle zugeschrieben werden kann ($P(m) > 0,5$), nicht vorhanden ist ($P(m) < 0,5$), oder keine Aussage darüber getroffen werden kann ($P(m) = 0,5$). Das Einbetten neuer Sensordaten $z \in Z$ in die bestehende Karte, welche auf Basis der vorher-gegangenen Messungen $Z \setminus z$ aufgebaut wurde, geschieht anhand des „Occupancy Grid Map“ Algorithmus: $P(m|Z)/(1-P(m|Z))=P(m|Z \setminus z)/(1-P(m|Z \setminus z)) \cdot P(m|z)/(1-P(m|z))$. Der Vorteil dieses Algorithmus ist die Onlinefähigkeit, welche die Fusion des bereits bestehenden Datensatzes mit neu eintreffenden Sensordaten zur Laufzeit erlaubt, solange diese Daten als sogenanntes inverses Sensormodel (ISM) $P(m|z)$ vorliegen.




Abb. 1: Evidenzkarten unterschiedlicher Eigenschaften (Hindernisse, Bestand, Bestandskante) aus dem Evidenzkartenstapel und deren farblich überlagerte Visualisierung

Die **Evidenzkarten** beschränken sich in unserem Ernteszenario von ihren physikalischen Ausmaßen auf eine „Region of Interest“ (ROI) um das Erntefahrzeug herum. Die ROI wird festen, globalen Koordinaten zugeordnet und ändert ihre Position nicht. Das Fahrzeug bewegt sich innerhalb der ROI, wobei die Evidenzkarte anhand eines ISM aktualisiert wird. Für die Beeinflussung des Dreschverhaltens können die Informationen aus der Evidenzkarte wieder abgerufen werden, um zum Beispiel das Dreschen von Fremdbestand durch selektives Anheben des Schneidwerkes zu vermeiden.

Sobald sich die Erntemaschine dem Rand der ROI nähert, wird sie neu zentriert und ein neuer Kartenabschnitt angelegt. Hierzu werden die alten Karten entsprechend verschoben, so dass die Sensorfusion kontinuierlich fortlaufen kann. Der neue Teilabschnitt der Evidenzkarte wird entweder mit unbekanntenen Werten, oder mit bereits für diesen Ort bekannten Informationen initialisiert.

Das **Inverse Sensormodel** (ISM) ist das Resultat einer intelligenten Sensordatenvorverarbeitung und stellt eine einheitliche Sensordatenschnittstelle dar, welche wiederum eine Evidenzkarte ist (siehe Abbildung 2). Hierzu werden die Daten eines einzelnen oder mehrerer Sensoren dazu verwendet, das ISM zu erstellen. Der hierzu verwendete Algorithmus wird als neuer virtueller Sensor definiert, während die Kombination aus einem oder mehreren Sensoren und Algorithmen als intelligenter Sensor bezeichnet wird. Das ISM muss für jeden Sensor speziell angepasst werden, sodass die Daten bestmöglich die zu erkennende Eigenschaft in der Kartenebene darstellen können. Dafür kann entweder empirisches Wissen über das Verhalten der Sensordaten oder ein Lernverfahren auf Basis von annotierten Daten verwendet werden [Th05, Ko11].

Zur **Sensordatenfusion** muss das ISM mit einer entsprechenden Karte aus dem Evidenzkartenstapel der ROI verrechnet werden. Da das ISM jedoch eine andere Auflösung haben kann oder sich in einem beliebigen Koordinatensystem befindet, muss zunächst das ISM in das ROI-Koordinatensystem transformiert werden. Danach können die jeweils überlappenden Zellen miteinander fusioniert werden.




Abb. 2: Messaufbau mit überlagertem Inversem Sensormodel (ISM) für Bestandswahrscheinlichkeit im Maschinenkoordinatensystem anhand eines LIDARs in Anbauhöhe der Fahrerkabine (links) und einzubettendes ISM im ROI (rechts)

In unseren aktuellen Arbeiten wird der Algorithmus mit unterschiedlichen Laserscanner- und Kameradaten versorgt, welche um das Fahrzeug angebracht sind und die Umgebung erfassen. Es werden algorithmisch unterschiedliche ISM auf Basis der Rohdaten zur Laufzeit erzeugt, um die Evidenzkarten, bestehend aus den Repräsentationen für Bestandseigenschaften, Hindernisse, Beiwuchs und Fahrspur, aufzubauen.

3 Systemarchitektur der Datenverarbeitung

Zur Bereitstellung und Verarbeitung der Daten wird eine eventbasierte Architektur verwendet, die mittels dem „Robotic Service Bus“ (RSB) realisiert wurde [Wi13]. Sobald neue Daten eines Sensors eintreffen, werden diese innerhalb eines TCP/IP basierenden Netzes zur Verfügung gestellt. Die Sensordatenvorverarbeitung greift diese Daten ab und erstellt das ISM daraus, welches wiederum von der Sensordatenfusion in die Evidenzkarte überführt wird. Die jeweils aktuelle Evidenzkarte kann dann zur Anzeige oder Inferenz abgefragt werden (siehe Abb. 3).

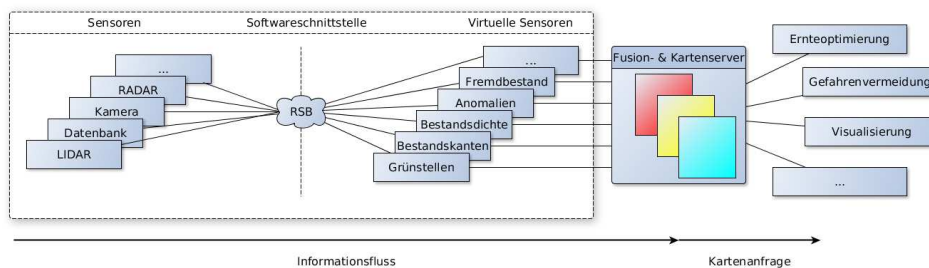


Abb. 3: Architekturübersicht der eventbasierten Kommunikation zwischen den Komponenten

4 Zusammenfassung und Ausblick

Unser Beitrag ist die Beschreibung unserer Realisierung eines neuartigen Ansatzes von der Datenakquise bis zur Sensordatenfusion und Bereitstellung der Informationen als Evidenzkarten in einem Ernteszenario. Anhand der Visualisierung der Evidenzkarte ist der Fahrer im Stande Eigenschaften des Umfeldes zu erkennen, welche entweder nur schwer (z.B. Verdeckung der Sicht) oder gar nicht (z.B. nicht-sichtbarer Pilzbefall im optischen Spektrum) von der Fahrerkabine aus zu erfassen sind. In unseren aktuellen Arbeiten wurde das vorgestellte System auf einer Erntemaschine implementiert und im Einsatz getestet, wodurch die funktionalen Eigenschaften unseres Beitrages bestätigt werden konnten. In weiteren Arbeiten sollen die Evidenzkarten zur Ernteoptimierung, Statistikerhebung, und Gefahrenabwehr verwendet werden. Zukünftig werden auch weitere Informationsquellen akquiriert, wie bereits vorhandene Kartenbestände oder weitere Erntemaschinen, um die Qualität der Evidenzkarten zu maximieren.

Literaturverzeichnis

- [El92] Elfes, A.: Dynamic control of robot perception using multi-property inference grids, 1992
- [Th05] Thrun, S., Burgard, W., Fox, D.: Probabilistic Robotics. Intelligent robotics and autonomous agents, MIT Press, 2005
- [Ko11] Kohlbrecher, S.: Grid-based occupancy mapping and automatic gaze control for soccer playing humanoid robots. 2011
- [Wi13] Wienke, J.: Moringen J.: Wrede S.: RSB – Robotics Service Bus, 2013
- [Ko15] Korthals, T.: Krause, T.: Rückert, U.: Evidence Grid Based Information Fusion for Semantic Classifiers in Dynamic Sensor Networks, 2015