

Sensorbasierte Anomalieerkennung bei autonomen landwirtschaftlichen Robotern durch Verwendung künstlicher Intelligenz

Gruber S.¹, Steinkellner H.², Bicici C. U.², Riegler-Nurscher P.², Gansberger M.¹

¹Fachhochschule Wiener Neustadt, ²Josephinum Research

Ausgangslage und Problemstellung

Autonome landwirtschaftliche Roboter sind sowohl mechanischen Belastungen als auch sicherheitskritischen Situationen ausgesetzt. Neben der zuverlässigen Ausführung ihrer Aufgaben ist eine kontinuierliche Überwachung der Arbeitsprozesse erforderlich, um fehlerfreies Arbeiten sicherzustellen. Da diese Systeme autonom agieren, muss auch die Überwachung des Roboters und seiner Umgebung autonom erfolgen. Eine zentrale Herausforderung besteht darin, Anomalien als Abweichungen vom Normalzustand zuverlässig zu erkennen. Dazu zählen technische Fehlfunktionen ebenso wie unerwartete Ereignisse in der Umgebung, etwa das Auftreten von Menschen oder Tieren.

Zielsetzung

Ziel dieses Projekts ist die Entwicklung eines modularen Sensorsystems zur kontinuierlichen Zustandsüberwachung landwirtschaftlicher Roboter sowie eines darauf aufbauenden KI-Systems zur Echtzeit-Anomalieerkennung. Die Verarbeitung multimodaler Sensordaten soll gegenüber unimodalen Ansätzen eine verbesserte oder mindestens gleichwertige Erkennungsleistung ermöglichen. Aufgrund der Seltenheit und häufig unbekanntem Natur von Anomalien werden überwiegend one-class, weakly-supervised und unsupervised Lernverfahren eingesetzt, die den Normalzustand der Maschine modellieren.

Methodik

Die Datengrundlage wurde durch ein iterativ entwickeltes Sensorsystem geschaffen, das zunächst eine RGB-Kamera und ein Mikrophon umfasste und auf realen Robotersystemen (siehe Abbildung 1) eingesetzt wurde. Die erhobenen Daten dienten dem Training der Modelle, während gezielt erzeugte Anomaliefälle zur Validierung herangezogen wurden.



Abbildung 1: Darstellung der verwendeten Robotersysteme. Links: Weinbauroboter Dionysos. Rechts: erweiterte Sensorplattform.

Ein erster Ansatz basiert auf Early Fusion, bei dem Audiodaten in Form von Spektrogrammen mit RGB-Bilddaten kombiniert wurden. Ein AutoEncoder lernte dabei ausschließlich den Normalzustand und rekonstruierte diesen im Betrieb. Anomalien wurden über Abweichungen zwischen Eingabe und Rekonstruktion identifiziert.

Ein alternativer Ansatz nutzt PatchCore [1], bei dem charakteristische Merkmale aus den Trainingsdaten extrahiert und in einer Datenbank gespeichert werden.

Im Betrieb erfolgt die Anomalieerkennung durch einen kNN-Vergleich neuer Features mit bekannten Mustern. Für die Featureextraktion wurden vortrainierte Netzwerke wie Wide ResNet 50-2 [2] eingesetzt.

Zur Erweiterung des eingeschränkten Sichtfelds kamerabasierter Systeme wurde das Sensorsetup um eine RGB-D-Kamera, LiDAR, RADAR sowie RTK-GNSS ergänzt. Die Fusion dieser heterogenen Daten erfordert eine präzise Synchronisation und erfolgt über domänenspezifische Featureencoder, die die Modalitäten in einen gemeinsamen Feature Space überführen. In diesem Raum wird die Anomalieerkennung mittels etablierter Verfahren wie Autoencoder oder PatchCore durchgeführt.

Ergebnisse

Die Integration von Mikrofonen erwies sich als ungeeignet, da Umgebungsgeräusche die relevanten Maschinensignale überlagerten. Bildbasierte Ansätze zeigten hingegen eine zuverlässige Anomalieerkennung sowohl mit Autoencoder- als auch mit PatchCore-Methoden (siehe Abbildungen 2 und 3).



Abbildung 2: Darstellung der Ergebnisse von Autoencoder. Links: Eingabe. Rechts: Rekonstruktion.




Abbildung 3: Darstellung der Ergebnisse von PatchCore mit Hilfe von Anomalib [3]. Links: Eingabe. Mitte: Anomaliekarte. Rechts: Anomaliemaske.

Der Autoencoder erfordert eine datensatzspezifische Schwellenwertbestimmung zur Trennung von Normalzustand und Anomalie, was den Anpassungsaufwand erhöht. PatchCore hingegen benötigt eine vorgelagerte Featureextraktion und ein Downsampling, erweist sich jedoch insgesamt als effizienter. Mit Hilfe von PatchCore konnte ein AUROC-Wert von 0,98 sowie ein F1-Score von 0,91 erreicht werden.

Schlussfolgerung

Die Ergebnisse zeigen, dass bildbasierte Verfahren bereits eine robuste Anomalieerkennung ermöglichen, unabhängig vom gewählten Modellansatz. Die Nutzung akustischer Daten ist im landwirtschaftlichen Umfeld aufgrund hoher Störgeräusche nur eingeschränkt geeignet, während Beschleunigungssensoren eine vielversprechende Alternative zur Erfassung maschinenspezifischer Schwingungen darstellen.

Für Punktwolken aus LiDAR und RADAR ist eine direkte Transformation in bildähnliche Repräsentationen nicht sinnvoll. Daher wurde für das erweiterte Sensorsetup ein Mid-Fusion-Ansatz über einen gemeinsamen Feature Space geplant.

Unsupervised bzw. weakly-supervised Anomalieerkennung ist für die Feldrobotik essenziell, da Anomalien selten auftreten und kaum vollständig gelabelt werden können. Modelle müssen daher den Normalzustand zuverlässig erlernen, um Abweichungen detektieren zu können.

Multimodale Fusion bietet großes Potenzial zur Steigerung der Robustheit, bringt jedoch Herausforderungen hinsichtlich Synchronisation und Echtzeitfähigkeit auf ressourcenbeschränkten Systemen mit sich. Die praktische Evaluation unter realen Einsatzbedingungen wird entscheidend für die Bewertung von Leistungsfähigkeit und Skalierbarkeit sein.

Danksagung

Dieses Projekt wurde durch die GFF Niederösterreich im Rahmen des Projekts FT123-G-009 gefördert. Besonderer Dank gilt der WALDLAND Holding GmbH für die Bereitstellung der Infrastruktur.



GEFÖRDERT IM RAHMEN DER FTI-STRATEGIE NIEDERÖSTERREICH 2027

Referenzen

- [1] Roth, K., Pemula, L., Zepeda, J., Schölkopf, B., Brox, T., & Gehler, P. (2022). Towards total recall in industrial anomaly detection. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 14318-14328).
- [2] Zagoruyko, S., & Komodakis, N. (2016). Wide residual networks. arXiv preprint arXiv:1605.07146.
- [3] Akcay, S., Ameln, D., Vaidya, A., Lakshmanan, B., Ahuja, N., & Genc, U. (2022, October). Anomalib: A deep learning library for anomaly detection. In 2022 IEEE International Conference on Image Processing (ICIP) (pp. 1706-1710). IEEE.