

Wie sich Künstliche Intelligenz in raumbezogenen Geschäftsprozessen einsetzen lässt

How Artificial Intelligence can be used in Geospatial Business Processes

Uwe Jasnoch

Zusammenfassung

Dieser Artikel beschreibt die verschiedenen Grundlagen einer KI-basierten Unterstützung von raumbezogenen Geschäftsprozessen. Zunächst werden grundlegende Prinzipien vorgestellt mit direktem Bezug zu den darauffolgenden Praxisbeispielen. Diese umfassen unter anderem eine einfache Objektklassifikation in einer automatisierten Analyse, inklusive Trainieren des Netzwerkes zur Steigerung der Qualität. Weitere Beispiele sind das Extrahieren von Informationen aus Punktfolgen und eine Veranschaulichung des Hybridansatzes. Dabei spielen Künstliche Assistenz sowie der Fokus auf die Überführung der Ergebnisse in automatisierbare Geschäftsprozesse jeweils eine tragende Rolle.

Schlüsselwörter: Künstliche Intelligenz, Raumbezogene Geschäftsprozesse, Neuronale Netzwerke, Öffentlicher Nahverkehr, Active Learning

Summary

This article describes the various fundamentals of AI-based support for geospatial business processes. First, basic principles are discussed with direct reference to the practical examples that follow. These examples include simple object classification in an automated analysis, including training the network to increase quality. Further examples are the extraction of information from point clouds and an illustration of the hybrid approach. Artificial assistance and the focus on transferring the results into business processes, that can be automated, play a key role in each case.

Keywords: Artificial Intelligence, Geospatial Business Processes, Neural Networks, Public Transport, Active Learning

1 Einleitung

Die gesteigerten Möglichkeiten der Sensorik führen zu einem stark erhöhten Datenaufkommen. Während die höhere Präzision der Sensoren – wie beispielsweise eine bessere Bodenauflösung bei Fernerkundungssensoren – die Geschäftsprozesse und deren Ergebnisse positiv beeinflussen, ist das damit verbundene Volumen der Daten eher prozessverhindernd. Damit ist der Weg für die Automatisierung geebnet, das heißt die Durchführung einzelner Prozessschritte und vollständiger Prozesse ohne menschliche Interaktion. Dies kann nur durch eine genaue Be-

schreibung der Algorithmen erfolgen, die in entsprechenden Modulen umgesetzt sodann automatisiert ablaufen.

Im Bereich der Objekterkennung – sei es im elektrooptischen oder im Punktwolke-Bereich – funktioniert diese Herangehensweise jedoch nur eingeschränkt, weil durch die zahlreichen Variablen, die den Datensatz beeinflussen können, die Algorithmik nicht in Gänze beschreibbar ist. Hier sind andere Ansätze gefragt, die mit Unschärfen entsprechend tolerant umgehen können. Es bieten sich Lösungen an, die auf Künstlichen Neuronalen Netzwerken aufbauen. Die Theorie stammt aus den frühen 1980er Jahren, aber die Hardware konnte damals die Netzwerke nicht mit angemessener Größe und Geschwindigkeit prozessieren. Erst durch die Anpassung der Netzwerke an die Eigenschaften von Grafikprozessoren sowie der Einsatz im kommerziellen Umfeld Anfang der 2000er Jahre, zum Beispiel bei Spurhalteassistenten oder Verkehrsschilderkennung im Automobilsektor, wurden die Voraussetzungen für einen effektiven Einsatz geschaffen.

In diesem Beitrag wird an drei Beispielen aufgezeigt, wie sich solche Neuronalen Netzwerke in raumbezogene Geschäftsprozesse einbinden lassen. Zunächst wird ein kurzer Abriss über einige Grundlagen gegeben, die für das Verständnis und die Lösungsansätze notwendig sind. Anschließend folgen Beispiele mit Hintergrundinformationen.

2 Grundlagen

Für einen vertieften Einblick in Grundlagen und Anwendungen der Künstlichen Intelligenz (KI) sei auf weiterführende Literatur verwiesen (z.B. Döbel et al. 2018). Im Bereich der Bildanalyse werden im Allgemeinen drei Ergebnisarten einer KI-Anwendung unterschieden, wie Abb. 1 darlegt.

- Die Unterschiede sind im Wesentlichen folgende:
- Bei der Objektklassifikation wird festgestellt, dass ein Objekt in dem Bild vorhanden ist.
 - Bei der Objekterkennung werden ein oder mehrere (antrainierte) Objekte im Bild detektiert und deren Position (repräsentiert durch eine Bounding Box) ermittelt.
 - Die Objektsegmentierung füllt in Ergänzung zur Objekterkennung auch noch die tatsächlichen Umrisse des Objektes aus.

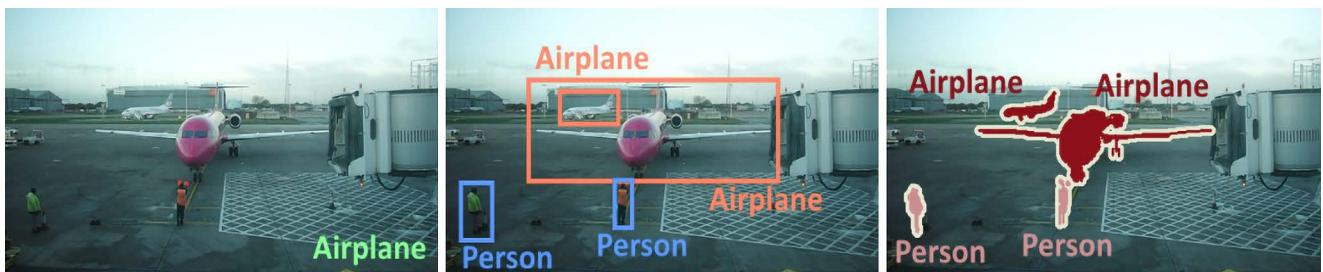


Abb. 1: Objektklassifikation, Objekterkennung und Objektsegmentierung

Naheliegenderweise nimmt die Komplexität der Berechnungen von der Objektklassifizierung bis zur -segmentierung zu. Zudem kommen auch unterschiedliche neuronale Netzwerktypen zur Anwendung, um zu den entsprechenden Resultaten zu gelangen. Allen gemeinsam sind aber gewisse Eigenschaften, die im Umgang mit Netzwerken zu berücksichtigen sind.

a) Netzwerke müssen trainiert werden

Damit neuronale Netzwerke Objekte klassifizieren, erkennen oder segmentieren können, müssen sie im Sinne der zu behandelnden Objektklassen trainiert werden. Auf Basis von bekannten Bildern, bei denen die Objekte entsprechend markiert (gelabelt) sind, werden die Netzwerke so lange trainiert, bis der Trainingsstand zufriedenstellend ist. Hierfür bieten verschiedene Werkzeuge entsprechende Hilfestellungen an.

b) Das Ergebnis ist nicht digital

Das Ergebnis einer neuronalen Netzwerk-Analyse drückt eine (prozentuelle) Wahrscheinlichkeit aus, dass ein Objekt entsprechend erkannt wurde. Je höher die Wahrscheinlichkeit, umso sicherer die Aussage. Da sich jedoch nur selten oder gar nie 100 % erreichen lassen, muss man sich über ein Vertrauensniveau verständigen, ab welchem die Wahrscheinlichkeit hinlänglich gut genug ist, damit der Geschäftsprozess stabil ablaufen kann.

c) Modelle haben unterschiedliche Eigenschaften

Es existieren Netzwerk-Modelle, die zwar sehr schnell trainierbar sind, deren Ergebnisse aber schlechtere Wahrscheinlichkeiten aufweisen. Im Gegensatz dazu kann man Modelle verwenden, deren Training einerseits aufwändiger ist, die andererseits aber deutlich zuverlässigere Resultate liefern. Verschiedene Daten erfordern unterschiedliche Modelle. So stehen unterschiedliche Modelle (und Netzwerke) bereit, je nachdem, ob Bilder, Videos oder Punktfolgen Verwendung finden. Ebenfalls ist die zu erwartende Antwortzeit zu berücksichtigen. Diesbezüglich gelten für Videos andere Kriterien als für Bilder. Dies bestimmt den zu betreibenden Hardwareaufwand.

Für Punktfolgen existieren spezielle Modelle, die auf die besonderen Anforderungen des Datenmaterials eingehen.

Abb. 2 stellt für Punktfolgen die Unterscheidung nach Klassifikation, Teilesegmentierung und semantischer Segmentierung dar. In der Praxis wird dies erst ab der Teilesegmentierung relevant, weil einzelne klassifizierte Punkte in der Wolke keinen inhaltlichen Wert bieten. Das heißt, ein entsprechender Einzelpunkt, der z. B. einem Tisch gehört, weist keinen Bezug zum Nachbarobjekt auf. Erst wenn alle Punkte klassifiziert und damit jeweils einem (Bau-)Teil zugeordnet wurden, kann eine Objektbildung erfolgen, die sich dann in Prozesse einbinden lässt.

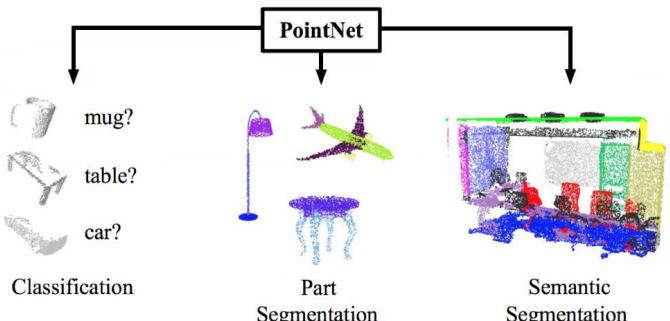


Abb. 2: Objektklassifikation und Segmentierungen in Punktfolgen

Die Herausforderungen liegen im Datenformat (ungeordnete Punktfolge, in der eine Struktur erkannt werden soll) und in der dreidimensionalen Räumlichkeit der Punktfolgen, da hierbei per se geometrische Transformationen im Raum erfolgen können (ausführlichere Diskussionen dieser Herausforderungen finden sich unter anderem in Qi et al. 2017 und Li et al. 2018). Eine Erkennungsplausibilität von 80 % markiert aktuell einen exzellenten Wert für Punktfolgen.

Setzt man Punktfolge und Bild in Bezug, sind die Vorteile des jeweiligen Mediums gut zu erkennen. Während Punktfolgen sehr gute Elemente hinsichtlich der 3. Dimension liefern, haben Bilder ihre Stärke in der Auswertung der Muster eines Objektes. So wird ein Verkehrsschild in der Punktfolge sehr gut bezüglich der Koordinaten erkannt, aber um welches konkrete Warnschild es sich handelt (dreieckiges Schild, Spitze nach unten), lässt sich nur über die Musterfähigkeiten der Bildanalyse erkennen. Deswegen ist der zielführende Weg eine hybride Auswertung (Bild und Punktfolge) für einige Objektklassen und Fragestellungen.

3 Anwendungsbeispiele

3.1 Objektklassifikation und Active Learning

Im ersten Anwendungsbeispiel sind zwei Fragestellungen zu beantworten, die wichtige Hinweise für Wartungsaufgaben der Verkehrsgesellschaft Frankfurt am Main – VGF geben:

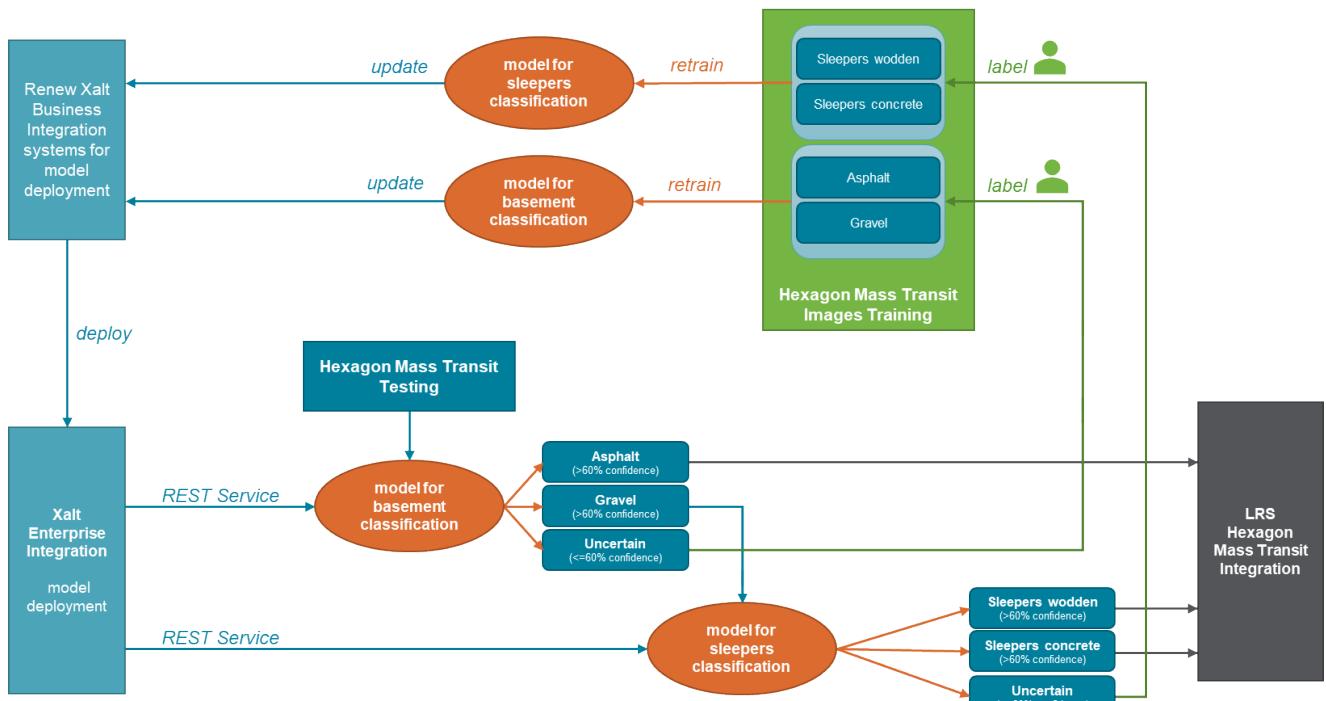
- Besteht das Gleisbett aus Asphalt, einem Grünstreifen oder Schotterbett?
- Wenn das Gleisbett in Schotter ausgeführt ist, bestehen die Schwellen aus Holz oder Beton?

Im Zuge der Lösungsfindung bei der Verkehrsgesellschaft Frankfurt am Main (VGF) wurde zuerst ein Netzwerk trainiert, das alle Fragen direkt beantwortet. Hierbei stellte sich jedoch heraus, dass die Wahrscheinlichkeiten der Objektklassifikation in der Praxis nicht zu erzielen sind. Im zweiten Ansatz wurden zwei Netzwerke trainiert, die exakt die Fragestellungen isoliert abbilden. Damit lassen sich

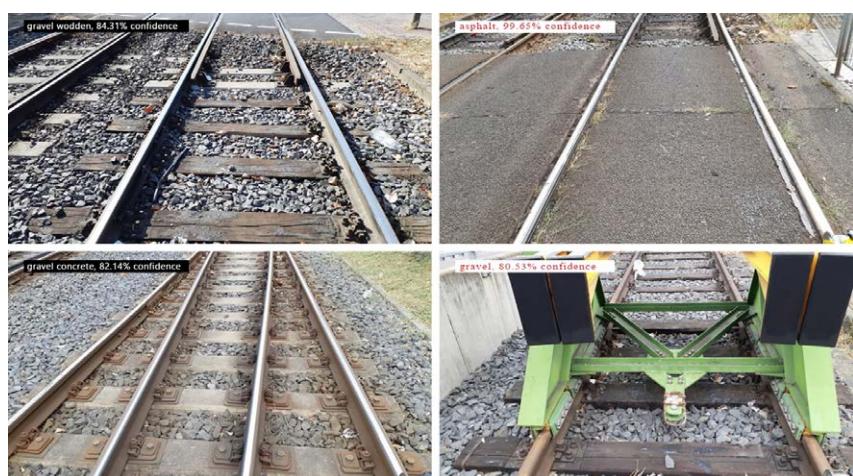
deutlich bessere Ergebnisse erzielen. Gleichwohl können die Klassifikationen ungenügend ausfallen – wenn zum Beispiel ungünstige Lichtverhältnisse keine eindeutigen KI-Aussagen zulassen.

Mit der VGF wurde ein Vertrauensniveau abgestimmt, ab welcher Wahrscheinlichkeit eine Aussage als ausreichend präzise gilt. Wird ein Wahrscheinlichkeitswert unterschritten, nimmt ein Mitarbeiter manuell die Erkennung und Markierung vor, sodass dieses Bild in einem späteren Trainingslauf einbezogen werden kann. So verbessert sich die Erkennungsgenauigkeit über die Zeit. Die Einbindung eines Mitarbeiters bezeichnet man als Active Learning (zu Active Learning vgl. Rubens et al. 2015).

Die beschriebene Lösung führt zur in Abb. 3 dargestellten prinzipiellen Architektur. Abb. 3 zeigt die Zweistufigkeit des Ansatzes mit der entsprechenden Feedback-Loop für nicht klassifizierbare Bilder. Abb. 4 veranschaulicht die Wahrscheinlichkeiten, wobei auch unter erschwerten Bedingungen (Bild unten rechts) robuste und belastbare Ergebnisse erzielt werden.



↑ Abb. 3:
Prinzipielle Architektur des Active Learning Systems für den ÖPNV



← Abb. 4:
Ergebnisse der KI-basierten Erkennung von Schwellentyp und Gleisbett

3.2 Erkennung von Objekten in Punktwolken

Im Kontext eines Forschungsvorhabens der UK Network Rail wurde eine Punktwolke eines rund 90 km langen Streckenabschnitts zur Verfügung gestellt, in dem 18 Objektklassen erkannt (segmentiert) werden sollten. Die Herausforderungen bestanden hier zuallererst in der Registrierung der Daten, da mehrere Scanfahrten miteinander verbunden werden mussten, um zu brauchbaren Elementen zu gelangen. Die Qualität der Klassifikation war letztlich divergent bezüglich der einzelnen Objektklassen; dies steht auch mit den geometrischen Eigenschaften der Objekte in Zusammenhang. So ließen sich etwa Strommasten oder Überführungen sehr präzise erkennen. Die Unterscheidung der Wandarten, z.B. Stützmauer oder Lärmschutzwand, war hingegen sehr diffus. Beispiele der erkannten Objekte zeigt Abb. 5 auf.

Im rechten Bereich von Abb. 5 wurde eine semantische Farbgebung gewählt. Gelb bezeichnet alle Elemente im Bereich Stromführung. Die erkannten Objekte können sehr gut im Bereich der Netz-/Infrastrukturdokumentation eingesetzt werden. Die Pflege bzw. Nachführung solcher datenbankgestützten Systeme ist entsprechend aufwändig, gleichwohl aber auch zwingend. Diese Systeme liefern die Grundlage für viele Belange des operativen Handelns, wobei Aktualität hierbei entscheidend ist. In diesem Projekt ließen sich insbesondere die Limitationen der alleinigen Punktwolkenauswertung aufzeigen.

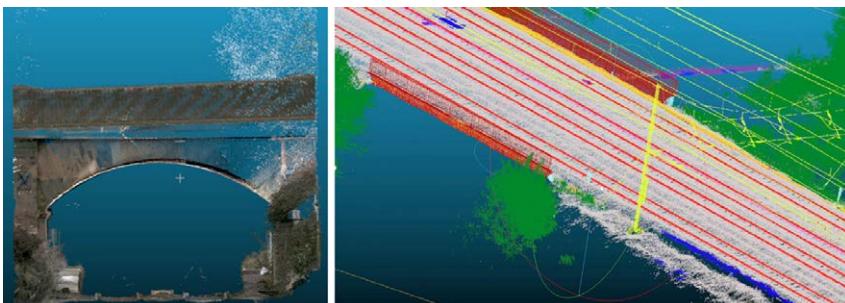


Abb. 5: Ergebnisse der KI-basierten Analyse einer Punktwolke



Abb. 6: Ergebnisse der KI-basierten Analyse von Dächern

3.3 Hybrider Ansatz

Für den hybriden Ansatz wurde ein urbanes Beispiel gewählt, bestehend aus Luftbildern und Punktwolken. Die Punktwolken können entweder via LiDAR Scanner erzeugt oder aber auch synthetisch via Semi-Global Matching erzeugt werden (zu Semi-Global Matching siehe Hirschmüller 2011).

Eine Aufgabe der Vermessungsverwaltung liegt in der Bestimmung der Landnutzung. Dabei wird eine entsprechende Kartierung der Nutzung basierend auf verschiedenen Quellen vorgenommen. Im Zuge eines Vorhabens der Landeshauptstadt Klagenfurt (Kärnten/Österreich) galt es, eine automatisierte Erkennung der Oberflächen aus 5 Terabyte Luftbildern (5 cm Bodenauflösung) mit der bislang üblichen manuellen Auswertung bzw. Vermessung zu vergleichen. Hierbei wurden neuronale Netze mit bereits trainierten 25 Objektklassen verwendet, um die Oberflächen automatisiert und ohne sensorspezifisches Nachtraining zu analysieren.

Anschließend wurden die Ergebnisse detailliert analysiert, um das Verbesserungspotenzial zu identifizieren. Im Bereich der Dacherkennung (2D) ergab sich ein Delta kleiner als 3 % (KI versus manuell), sprich 739 nicht korrekt erkannte Dächer von insgesamt 24.861. Diese Quote ließ sich durch die Erzeugung einer synthetischen Punktwolke nochmals signifikant verbessern. Ein beispielhaftes Resultat zeigt Abb. 6.

Die Ergebnisse der qualifizierenden Auswertung der Landnutzung können durch Anwendung weiterer Verfahren in Vektorobjekte überführt werden, die sich danach in Geschäftsprozessen einsetzen lassen. Abb. 7 verdeutlicht verschiedene Schritte, die letztlich zu einem Vektordatensatz von Bäumen führen.

Diese Vektorobjekte, verschnitten mit bekannten Infrastrukturobjekten (hier Gleisanlage), identifizieren alle Bäume einer gewissen räumlichen Nähe und Höhe, die eine potenzielle Gefährdung des Eisenbahnverkehrs im Falle eines Sturmes darstellen – wie Abb. 8 aufzeigt.

Die Zusammenführung der verschiedenen Ansätze kann entsprechend in einen Geschäftsprozess münden, der die präventive Baumkontrolle zu optimieren hilft.

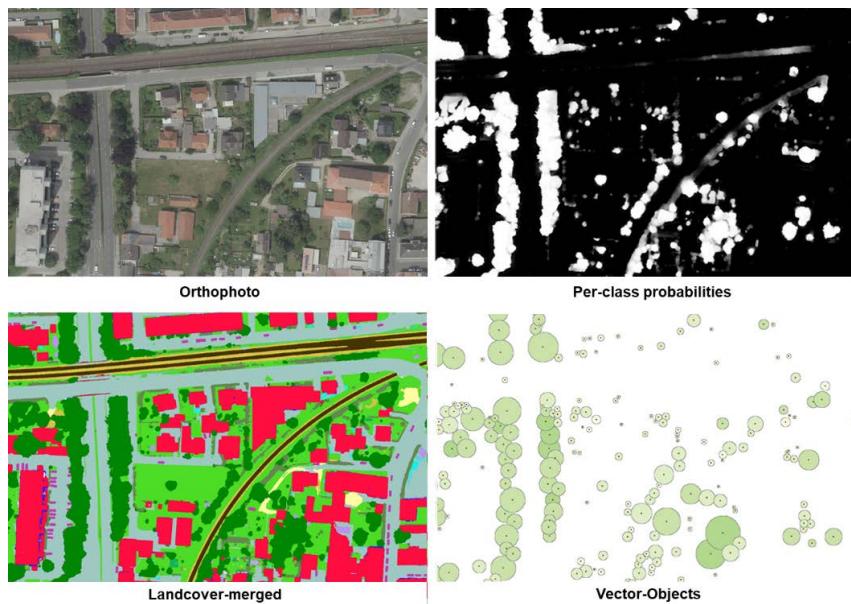


Abb. 7: Ergebnisse der KI-basierten Analyse, die zur Erzeugung von Vektorobjekten führen.



4 Zusammenfassung

In diesem Beitrag werden verschiedene Grundlagen einer KI-basierten Unterstützung von Geschäftsprozessen diskutiert. Dabei liegt der Fokus weniger auf technischer Tiefe als vielmehr auf der Darstellung wichtiger Prinzipien, die helfen, die anschließenden Praxisbeispiele besser zu verstehen.

Im ersten Beispiel wird aufgezeigt, wie eine einfache Objektklassifikation in einer automatisierten Analyse mündet, bei der auch das erneute Trainieren des Netzwerkes zur Steigerung der Qualität Berücksichtigung findet. Welche

Informationen sich aus Punktfolgen extrahieren lassen, zeigt das zweite Anwendungsbeispiel auf. Hier erfolgt ein Hinweis insbesondere auf die Grenzen der reinen Punktfolgenerkennung. Ein abschließendes Beispiel veranschaulicht den Hybridansatz. Dabei führt ein (Teil-)Aspekt der Auswertung zur Generierung von Vektorobjekten, die sich dann in weiteren Schritten in einer automatisierten Anwendung zur Baumkontrolle einsetzen lassen.

Allen Beispielen gemeinsam ist die Assistenzfunktion, die die Künstliche Intelligenz hier in der Bewertung einnimmt, sowie der Fokus auf der Überführung der Ergebnisse in automatisierbare Geschäftsprozesse.

Literatur

- Döbel, I., et al. (2018): Maschinelles Lernen – Kompetenzen, Anwendungen und Forschungsbedarf. Fraunhofer-Gesellschaft (Hrsg.), Ergebnisbericht zum Förderprojekt 01IS17019.
- Hirschmüller, H. (2011): Semi-Global Matching – Motivation, Developments and Applications. In: Fritsch, D. (Hrsg.): Proceedings Photogrammetric Week 2011, 173–184.
- Li, Y., Bu, R., Sun, M., Wu, W., Di, X., Chen, B. (2018): PointCNN: Convolution on χ -transformed Points. In: Bengio, S., Wallach, H.M., Larochelle, H., Grauman, K., Cesa-Bianchi, N. (Hrsg.): Advances in Neural Information Processing Systems. 31. Proceedings 32nd Conference on Neural Information Processing Systems (NeurIPS 2018), 820–830.
- Qi, C.R., Su, H., Kaichun, M., Guibas, L.J. (2017): PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Vol. 1, 77–85.
- Rubens, N., Elahi, M., Sugiyama, M., Kaplan, D. (2015): Active Learning in Recommender Systems. In: Kantor, P.B., Ricci, F., Rokach, L., Shapira, B. (Hrsg.): Recommender Systems Handbook, 809–846.

Kontakt

Uwe Jasnoch
Vice President Business Development
Hexagons Safety, Infrastructure & Geospatial Division
info.de.sig@hexagon.com

Dieser Beitrag ist auch digital verfügbar unter www.geodaeis.info.