

Künstliche Intelligenz als Strategie in der Ingenieurgeodäsie – erste Schritte im Bahnumfeld

Bastian Plaß, Kira Zschiesche, Tamer Altinbas, Daniel Karla, Linda Rau und Martin Schlüter

Zusammenfassung

Für die Arbeiten im Gleisbereich ist ein System zur Erfassung von Zugfahrten unverzichtbar. Künstliche Intelligenz kann einen Teil dazu beitragen. Im Folgenden wird ein erster Ansatz, basierend auf Deep Learning Technologie, vorgestellt, welcher auf Grundlage von Bilddaten automatisch Züge detektiert und so zu mehr Sicherheit im Gleisbereich beitragen kann. Darüber hinaus ist eine Softwarelösung entwickelt worden, welche den umfangreichen und bisher arbeitsintensiven Datenvorbereitungsaufwand signifikant reduziert. Im vorliegenden Beitrag werden das Potenzial und die flexible Einsetzbarkeit von Künstlicher Intelligenz im ingenieurgeodätischen Kontext aufgezeigt.

Abstract

A system for recording train rides for work in the track area is crucial. The usage of Artificial Intelligence contributes to this. In the following article a first approach based on Deep Learning is presented, that automatically detects trains on the base of image data and can lead to more safety in the track area. In addition, a software has been developed that reduces the extensive and work-intensive data preparation effort significantly. This article presents the potential and the flexible deployment of Artificial Intelligence in the engineering geodetic domain.

Schlüsselwörter: Deep Learning, Convolutional Neural Network, Künstliche Intelligenz, Zugdetektion, Rottenwarnanlage

1 Anwendungskontext und Motivation

Die Ingenieurgeodäsie tritt als Dienstleister in einem breiten Domänenpektrum auf. Insbesondere der sichere Umgang mit Präzisionsmessungen, Datenmanagement, Referenz- und IT-Systemen ist ein maßgebliches Alleinstellungsmerkmal der modernen, interdisziplinären Geodäsie. Verfahren der Künstlichen Intelligenz (KI) beschränken sich gegenwärtig nicht mehr nur auf die Softwareindustrie, sondern rücken immer weiter in die unterschiedlichsten Branchen vor. So gewinnt dieses Werkzeug auch im Bereich des geodätischen Arbeits zunehmend an Bedeutung. Cha et al. (2017) sowie Cha und Wang (2017) präsentieren die Möglichkeit, Risse in Betonbauwerken zu erkennen. Dabei werden Daten aus unbemannten Flugsystemen (UAV) mittels künstlicher neuronaler Netzwerke (KNN) verarbeitet. In Musella et al. (2019) wird Building Information Modeling (BIM) mit KI zur Erkennung seismischer Schäden an Mansarden-



Mit freundlicher Genehmigung der Unternehmensgruppe Zöllner Signal GmbH

Abb. 1: Warngeberkette



Mit freundlicher Genehmigung der Stadtwerke Verkehrsgesellschaft Frankfurt am Main mbH

Abb. 2: Gleisarbeit

gebäuden verknüpft. Das Konsortium »KI meets BIM«, in welchem auch der Lehrstuhl Informatik im Bauwesen der Ruhr-Universität Bochum (RUB) vertreten ist, legt einen Forschungsschwerpunkt auf die automatisierte Bauablaufplanung und strebt die Umsetzung mit Hilfe von Laserscannern an. Zum Bereich des spurgebundenen Baustellen-Monitorings gehört auch die Sicherung der Baustellen (Abb. 1).

Dazu zählt u.a. die lückenlose Erfassung und zuverlässige, ortsgerechte Weitergabe von Zugfahrten in den verschiedensten Gefahrensituationen, um dem Baustellenpersonal (Rotte) die rechtzeitige Räumung des Gleisbereichs zu ermöglichen. Üblich ist der Einsatz sogenannter Rottenwarnanlagen, welche von Sicherungspersonal (Sakra) beaufsichtigt werden und mit Hilfe mechanischer, induktiver oder elektromagnetischer Sensoren den Zug streckenseitig detektieren, um die Rotte über akustische und optische Reize zu warnen (Abb. 2).

Im folgenden Anwendungsbeispiel soll experimentell KI eingesetzt werden, um in Bilddaten automatisiert

Züge zu detektieren und so zu mehr Sicherheit im Gleisbereich zu führen. Als »drittes Auge« soll es das Portfolio an automatischen Warnanlagen und damit die sicherheitskritische Systemarchitektur erweitern. Durch den Einsatz einer Kamera in Verbindung mit einer trainierten KI kann die Bandbreite der bisher eingesetzten Sensorik praktikabel und kostengünstig ausgebaut werden. Mit Reduzierung der Aufwands- und Instandhaltungskosten bei gleichzeitiger Erweiterung des Sichtfeldes zwecks Erhöhung der Arbeitssicherheit sind die Vorteile des Computer-Vision-Systems allgemein beschrieben.

2 Bildverarbeitung durch Machine Learning

Computersysteme in die Lage menschlichen Wahrnehmens und Handels zu versetzen, ist Gegenstand der KI-Forschung. Ein populärer Zweig der KI ist das Machine Learning (ML). Durch ein umfangreiches Training können Maschinen für eine eng definierte Aufgabe ausgebildet werden. Dabei beruht die Intelligenz auf der Erkennung von Mustern und Gesetzmäßigkeiten innerhalb der Daten. Als ein effektives Werkzeug im Bereich der Bilderkennung haben sich KNN herausgestellt, mit welchen z.B. herannahende Züge in Bildern erkannt und diese entsprechend klassifiziert werden können. Der weitreichende Erfolg von KNN ist einerseits auf große Mengen an verfügbaren Trainingsbildern zurückzuführen, welche unter hoher Rechenleistung verarbeitet werden, um die relevanten Merkmale für die Klassifikationsaufgabe zu bestimmen. Andererseits erlauben KNN eine beliebig tiefe Staffelung ihrer Schichtenarchitektur, wodurch auch sehr komplexe Merkmale gelernt werden können und sich der Begriff Deep Learning (DL) definiert.

Je hochwertiger die Trainingsbilder und vielseitiger die Perspektiven sind, desto robuster erlernt das KNN die Objektmerkmale und kann diese durch ein mathematisches Modell beschreiben. Nach der Beendigung des Trainings ist das Modell in der Lage, unbekannte Bilder

zu klassifizieren. Dieser Vorgang des Schlussfolgerns aus trainierten Erfahrungswerten wird als Inferenz bezeichnet (vgl. Abb. 3). Training und Inferenz stehen nicht direkt in Verbindung, jedoch bedingt die Inferenz einen vorgesetzten Trainingsprozess, aus welchem ein Modell resultiert, das den Wissensstand enthält.

3 Einleitung Deep Learning

Durch DL erlebt KI zurzeit eine Renaissance. Dabei ist die Lösung von Computer-Vision-Aufgaben mit einer speziellen Klasse von KNN lediglich ein Teilbereich in einem weitreichenden Feld von Anwendungsszenarien. Diese sog. Convolutional Neural Networks (ConvNets) bestehen aus verschiedenen Schichten, die sich in ihrer Anzahl, Tiefe und den implementierten Aktivierungs- sowie Optimierungsfunktionen unterscheiden. Bezeichnend für ein ConvNet sind die sog. Convolutional Layer, die eine mathematische Faltung der Bildinformationen vornehmen und in der Regel von einem Pooling Layer zur Verdichtung der Informationen gefolgt sind. ConvNets sind in der Lage, die für die Problemstellung notwendige Mustererkennung und -extraktion eigenständig zu erlernen (LeCun et al. 1999). Damit entfallen die manuelle Suche und die Vorverarbeitung der Bilder. Diese zu lernenden Parameter (Gewichte) gehen häufig in die Millionen und manifestieren sich durch Filter-Kernels, welche die originären Bildinformationen zu Merkmalskarten abstrahieren und worauf abschließend die Bildklassifikation basiert. Bei ConvNets erfolgt der Trainingsprozess vollautomatisch und ohne Möglichkeit der Einsicht in die Informationsverarbeitungskette. Mit Hilfe sog. Hyperparameter kann jedoch der Trainingsprozess von außen gesteuert und somit die Ergebnisse optimiert werden. Im Bereich der Bilderkennung wird heute auf überwachte Lernmethoden gesetzt. Diese setzen einen großen Datenbestand an Bilddaten sowie deren Zielwerte (Annotationsen) voraus (Goodfellow et al. 2016).

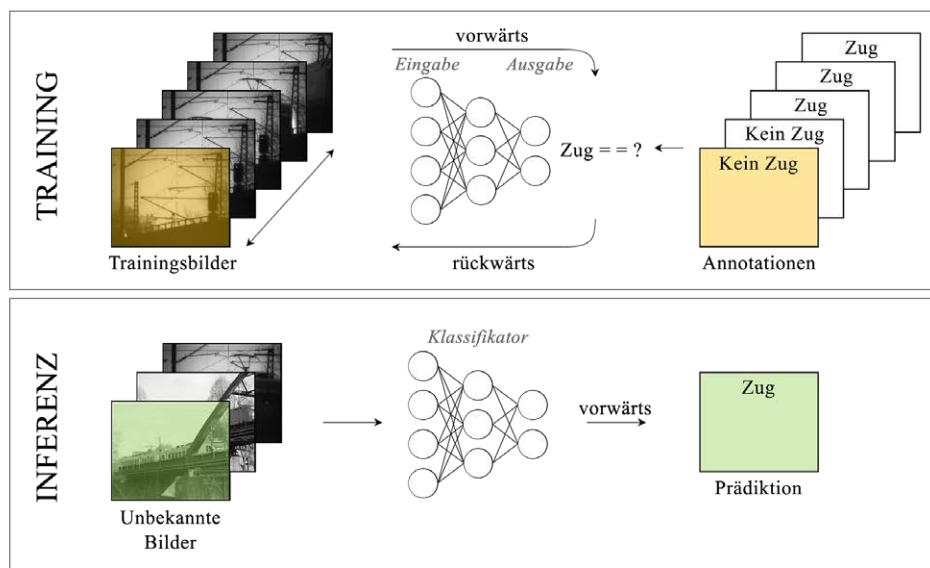


Abb. 3:
Während des Trainings werden die Verbindungen zwischen den in Schichten organisierten Neuronen (○) des ConvNets gewichtet, sodass diese während der Inferenzphase den Anwendungsfall bestmöglich beschreiben können.

4 Datenbestände

Das Training eines DL-Modells für eine konkrete Problemstellung setzt einen umfangreichen, zielgerichteten Bilddatensatz sowie deren Annotationen voraus. Um diesen Trainingsdatensatz zu erheben und auszuwerten, werden große Ressourcen benötigt. Bekannte Modelle zur Bilderkennung, wie bspw. AlexNet (2012), VGG (2014), ResNet (2015) oder Xception (2016), sind auf vielen Millionen Bilddaten trainiert, welche sukzessiv durch eine weltweite Gemeinschaft erzeugt werden. Eine der populärsten und umfangreichsten Bilddatenbanken ist ImageNet mit über 14 Millionen Datensätzen (Deng et al. 2009). Durch die freizügige Lizenz und breite Kategorisierung prädestiniert sich diese Datenbank für das Training von ConvNets. Da ein Training von Grund auf nicht nur massive Rechenleistung, sondern auch Zeitkapazität benötigt, werden von Universitäten und Technologieunternehmen vortrainierte Modelle veröffentlicht. Diese können durch das Transferlernen mit einem signifikant kleineren Datensatz und Zeitaufwand anschließend wieder verwendet und so auf einen anderen Anwendungsfall angepasst werden (Pan und Yang 2010).

MVTec bietet in der Bildverarbeitungssoftware HALCON eine DL-Toolbox mit vortrainierten Modellen an. Diese wurden auf internen, industrienahen Bildern ausgebildet und stehen für die weitere Verwendung zur Verfügung (IDS Imaging Development Systems GmbH und MVTec Software GmbH 2018). Die Adaption auf die Anwendung im Gleisbereich erfordert folglich einen zielgerichteten Domänendatensatz, welcher durch OpenData-Plattformen, wie z.B. railserve.com, nicht ausreichend bedient werden kann. Infolgedessen wurden manuell Bilder diverser Zugtypen aufgenommen: nicht komprimiert, ungefiltert, mit unterschiedlichen Kamerasensoren, an unterschiedlichen Örtlichkeiten, von unterschiedlichen Positionen. Je abwechslungsreicher die Bilder sind, desto robuster verhält sich das trainierte Modell gegenüber Bildvariationen.

5 Klassifizierung

Hinter der maschinellen Bilderkennung verbirgt sich eine überwachte Lernmethode. Diese setzt annotierte Bilddaten voraus, welche der Maschine das Lernziel vorgeben und darüber hinaus für die Merkmalsrepräsentation verantwortlich sind. Die binäre Bildklassifikation ist eine vergleichsweise einfache Aufgabe, wobei das System lediglich lernen soll, ob das gesuchte Objekt abgebildet ist. Damit ist der Klassifizierungsaufwand limitiert, aber dennoch skalierbar. Im Rahmen des Projekts wurde eine klassische Form der Bildverarbeitung getestet, um den für das Training notwendigen Datenbestand vorzubereiten. Aus der Aufnahme der Gleissituation resultiert ein zeitbezogener Bildreihendatensatz. Die Berechnung von Differenzbildern ist über einen Schwellwert und ein zu

spezifizierendes Bildintervall steuerbar. Die Eigenevaluation des Verfahrens stellt im Vergleich zur manuellen Klassifizierung eine Beschleunigung um den Faktor 3 bei einer Fehlerquote im niedrigen einstelligen Bereich dar. Dieser Ansatz trägt dazu bei, den manuellen Datenvorbereitungsaufwand erheblich zu reduzieren.

6 Training

Aus einer MVTec HALCON Anwendung wird die Klassifizierungsaufgabe der Zugdetektion abgeleitet. Dabei bietet HALCON vortrainierte Bildklassifikatoren an, die bereits auf internen Daten ausgebildet sind und übertragbare Objektmerkmale erlernt haben. Das Nachtraining erfordert somit eine signifikant geringere Menge an Trainingsdatensätzen. Das MVTec ConvNet *compact* erwartet Eingabebilder der Dimension $224 \times 224 \times 3$ (Breite · Höhe · Farbkanäle). Der sequenziell erhobene Datensatz weist eine Größe von 17.539 Bildern auf, welche disjunkt und im Verhältnis 70 : 15 : 15 aufgeteilt sind. Der größte Anteil des Gesamtdatensatzes, die sog. Trainingsbilder, sind für die Optimierung des ConvNets verantwortlich, während Validierungs- und Testbilder u.a. zur Bewertung der Leistungsfähigkeit herangezogen werden. Eine Datenaugmentierung, zur synthetischen Vergrößerung des Bilddatensatzes, soll Divergierungseffekten wie Overfitting entgegenwirken und die Klassifizierungsleistung steigern. Dabei wird die Augmentierung durch

- Spiegelung,
- Grauwertanpassung und
- Hinzufügen eines lokalen Helligkeitsspots

umgesetzt. Damit steigt die Anzahl der Trainingsbilder um den Faktor 4 an. ConvNets sind schichtweise organisiert (vgl. Abb. 3). Jedes Bild wird durch eine Reihe von Filtern sowie Aktivierungsfunktionen, zusammengefasst als Gewichte, und Downsampling-Strategien abstrahiert. Die daraus resultierenden Merkmalskarten (engl. Feature Maps) weisen verschiedenen Regionen bzw. Objekten im Bild eine Wichtigkeit und damit Unterscheidbarkeit im Kontext der globalen Fragestellung zu. Beim überwachten Lernen wird die Aussage des ConvNets dem Zielwert gegenübergestellt (vgl. Abb. 3). Durch die gegebene Klassifizierung kann das ConvNet die Optimierung der Gewichte eigenständig vornehmen, weshalb auch von Ende-zu-Ende trainierten Netzen die Rede ist. Die Anpassung der Gewichtung erfolgt durch eine Fehlerrückführung (engl. Backpropagation of Error) automatisch und stellt ein Gradientenabstiegsverfahren dar, welches speziell auf mehrschichtige Netze optimiert ist.

Der Verlauf des Trainings wird durch eine zeitabhängige Verlustfunktion visualisiert, welche den mittleren Fehler über einen zu spezifizierenden Stapel an Bilddaten angibt. Sofern die Verlustfunktion auf den Trainingsbildern stetig sinkt und sich konvergierend gegenüber dem mittleren Fehler aus den Validierungsbildern verhält, lernt das ConvNet generalisierte Objektrepräsentationen.

Das Auseinanderdriften zwischen jenen Verlustfunktionen innerhalb des Trainingsprozesses lässt auf eine Überanpassung und damit Auswendiglernen schließen. Dieser Zustand ist unerwünscht und in jedem Fall durch Rekonfiguration des ConvNets zu eliminieren.

In Abhängigkeit der zugrunde liegenden Netzwerktopologie und des spezifischen Anwendungsfalls existiert eine Reihe von Hyperparametern. Innerhalb eines systematischen Optimierungsprozesses (engl. Hyperparameter Tuning) werden jegliche Stellschrauben innerhalb des ConvNets auf die Klassifizierungsaufgabe ausgerichtet, um das bestmögliche Modell basierend auf den Trainingsbildern zu generieren. Im Rahmen des Projektes führte ein Stapel (engl. Batch) von 32 Bildern, eine schrittweise Anpassung der anfänglichen Lernrate (engl. Learning Rate) von 0,001 und ein Regularisierungsterm anstelle des Dropouts zu dem besten Modell. Der statistisch-basierte Trainingsprozess endet nach einer spezifizierten Iterationsanzahl oder bei Unterschreiten eines gesetzten Fehlerschwellwertes. Im Anschluss daran wird das Modell final evaluiert.

7 Evaluation

Nach Abschluss des Trainingsprozesses wird das Modell mit dem geringsten Fehler bewertet. Die Evaluation quantifiziert die abschließende Leistungsfähigkeit des Modells, wodurch der Zusammenstellung der Testdaten eine besondere Bedeutung zukommt. Diese müssen vor allem den zukünftigen Anwendungskontext uneingeschränkt erfüllen, um zu einer zuverlässigen Kennzahl zu führen. Die Vorhersagequalität des Modells wird im vorliegenden Fall durch den Top-1-Score quantifiziert. Der Begriff Top-1 stellt eine Methode zum Benchmarking von ML-Modellen dar, welche im Bereich von Bildklassifikationsaufgaben populär ist und auch in Krizhevsky et al. (2012) zur Anwendung kommt. Das ConvNet schätzt für jede Klasse eine Wahrscheinlichkeit, deren Summe wiederum 1 ergibt. Die Klasse mit der höchsten Wahrscheinlichkeit stellt das Ergebnis der Klassifikationsaufgabe dar. Im Falle des Top-1-Fehlers wird geprüft, ob das prädiizierte Ergebnis nicht mit der Annotation übereinstimmt. Der Quotient aus der Summe nicht richtig klassifizierter Bilder und der Gesamtheit der Bilder ergibt den Top-1-Fehler: Je geringer der Fehler, desto treffsicherer klassifiziert das ConvNet.

Die abschließende Leistungsfähigkeit eines Modells lässt sich u.a. mit Hilfe des Testfehlers quantifizieren (s. Abb. 4). Die Interpretation dieses Fehlers stellt zugleich eine wichtige Aufgabe, aber auch große Herausforderung dar, da dieser die semantische Bedeutung der für die Klassifikation entscheidenden Bildregion nicht berücksichtigt. ConvNets verarbeiten Informationen auf sehr komplexe Weise, sodass eine gesicherte Aussage über die gelernten Merkmale in den Bildern nicht durch die Bewertung des Testfehlers abgedeckt ist (Lei et al. 2018,

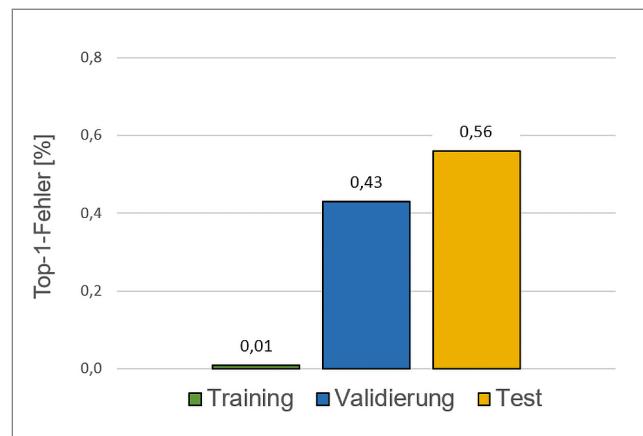


Abb. 4: Leistungsfähigkeit des besten Modells nach 100 Trainingsiterationen. Eine Iteration steht gleichbedeutend für den Durchlauf der gesamten Trainingsbilder.

Shwartz-Ziv und Tishby 2017). Eine anschauliche Begründung liefert Ribeiro et al. (2016), dessen Modell Husky-Hunde klassifizieren sollte, aber letztlich Schnee als beschreibendes Objektmerkmal erlernt hat. Ähnlich könnte es sich im hier untersuchten Anwendungsfall verhalten, indem das Modell Gleise, Einzäunungen oder Fahrsignale als Zug interpretiert. Um dem entgegenzuwirken, werden sowohl Heatmaps verwendet als auch die Datenaugmentierung auf solche Fehlmerkmale abgestimmt, hier z.B. durch das Hinzufügen eines Helligkeitsspots (vgl. Abschnitt 6).

In der KI-Forschung werden über aussagekräftige Metriken zur Quantifizierung der Leistungsfähigkeit eines Bildklassifikators hinaus verschiedene Visual-Analytics-Komponenten entwickelt, um die gelernten Merkmale zu visualisieren und so zu einem besseren Verständnis über das trainierte Modell zu gelangen. MVTec HALCON stellt zu letzterem Heatmaps bereit (s. Abb. 5). Diese Komponente zeigt auf, welche Bildregion für die Klassifizierung ausschlaggebend ist. Mit Hilfe dieser Regionen können wichtige Informationen, wie die erlernten Merkmale für die Klasse »Zug«, abgeleitet und zur Evaluation hinzugezogen werden. Dabei stellen die Heatmaps jedoch keine Segmentierung von Zügen im Bild dar (vgl. MVTec Software GmbH 2019). Mit den erreichten Ergebnissen lässt sich nachvollziehbar visualisieren, dass das Modell die markanten Strukturen eines Zuges erlernt hat.

8 Fazit

Der in diesem Artikel vorgestellte Workflow zur automatischen Erkennung von Zügen in Bilddatensätzen wurde erfolgreich getestet. Experimentell werden an dem vorliegenden Beispiel erste Erkenntnisse über die Einsetzbarkeit von KI in einer ingenieurgeodätischen Domäne gesammelt. Die vorliegende Problemstellung beinhaltet die Bildklassifizierung in zwei Klassen. Dabei soll auf Grundlage eines trainierten DL-Modells automatisch erkannt werden, ob im Bild ein Zug vorhanden ist oder nicht.

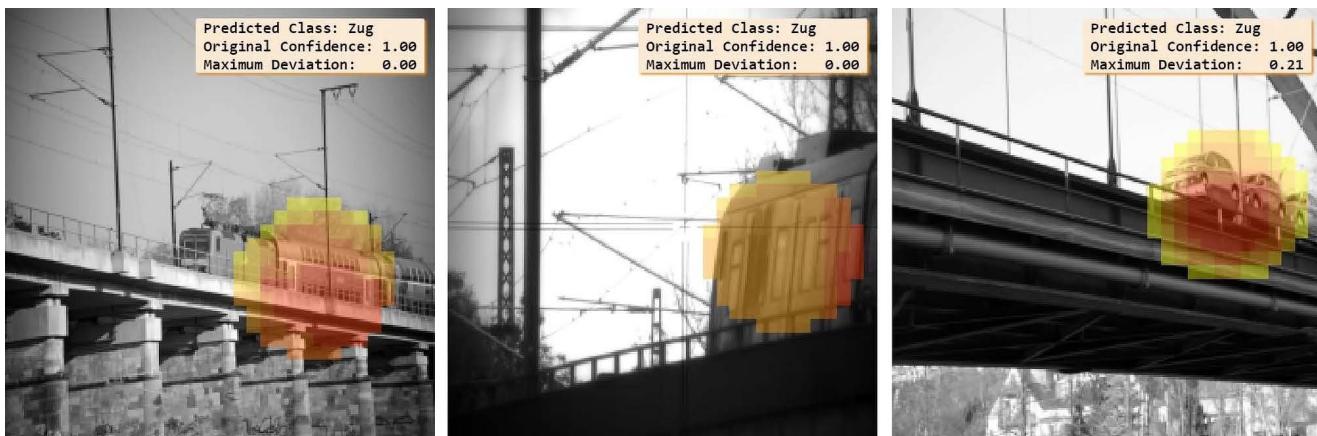


Abb. 5: MVTec Heatmaps

Durch die Verwendung einer KI kann vollständig auf die explizite Formulierung funktioneller Zusammenhänge verzichtet werden. Es zeigt sich, dass der eingesparte Aufwand für ein optimales Ergebnis in die Datenakquise und die Annotation fließen sollte, da die Erzeugung des Trainingsdatensatzes wichtige Erkenntnisse um das Paradigma DL erfordert und folglich die Güte des DL-Bildklassifikators limitiert. Durch die softwareseitige Lösung der Bildklassifizierung kann der manuelle Arbeitsanteil deutlich gesenkt werden und somit erheblich zur Wirtschaftlichkeit des »dritten Auges« beitragen. Der verwendete Differenzbildansatz ist jedoch nur bei vorhandenen Bildreihen sinnvoll einsetzbar.

Im Rahmen dieses Forschungsprojektes wurde ein vortrainiertes ConvNet erfolgreich auf einen spezifischen Anwendungsfall adaptiert. Der resultierende Bildklassifikator hat sich als praxistauglich erwiesen. Bezugnehmend auf die Sicherung von Arbeitsstätten im Gleisbereich unterstreicht unser Ergebnis das Potenzial von DL-basierten Computer-Vision-Systemen.

Dank

Dieses Projekt wird durch die Carl-Zeiss-Stiftung gefördert.

Literatur

- Cha, Y.-J., Choi, W., Büyüköztürk, O. (2017): Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. In: Computer-Aided Civil and Infrastructure Engineering 32 (5), 361–378. DOI: 10.1111/mice.12263.
- Cha, Y.-J., Wang, Z. (2017): Unsupervised novelty detection-based structural damage localization using a density peaks-based fast clustering algorithm. In: Structural Health Monitoring, 147592171769126. DOI: 10.1177/1475921717691260.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L. (2009): ImageNet: A Large-Scale Hierarchical Image Database. In: 2009 IEEE Conference on Computer Vision and Pattern Recognition. Conference on Computer Vision and Pattern Recognition. Miami, FL, USA, 22.06.–24.06.2009: IEEE.
- Goodfellow, I., Bengio, Y., Courville, A. (2016): Deep Learning. Cambridge, Massachusetts: The MIT Press (Adaptive Computation and Machine Learning series). <https://lccn.loc.gov/2016022992>, letzter Zugriff 30.01.2020.
- IDS Imaging Development Systems GmbH und MVTec Software GmbH (2018): Bildverarbeitungs-Anwendungstage 2018. Von Deep Learning über Robotik bis 3D-Vision. Frankfurt, 11.07.2018.

Krizhevsky, A., Sutskever, I., Hinton, G. (2012): ImageNet Classification with Deep Convolutional Neural Networks. In: Neural Information Processing Systems 25. DOI: 10.1145/3065386.

LeCun, Y., Haffner, P., Bottou, L., Bengio, Y. (1999): Object Recognition with Gradient-Based Learning. In: Shape, Contour and Grouping in Computer Vision. Berlin, Heidelberg: Springer Berlin Heidelberg, 319–345.

Lei, D., Chen, X., Zhao, J. (2018): Opening the black box of deep learning. <http://arxiv.org/pdf/1805.08355v1.pdf>, letzter Zugriff 30.01.2020.

Musella, C., Serra, M., Menna, C., Asprone, D. (2019): BIM & AI: advanced technologies for the digitalisation of seismic damages in masonry buildings. In: International fib Symposium on Conceptual Design Of Structures. International fib Symposium on Conceptual Design Of Structures. Madrid, September.

MVTec Software GmbH (2019): Klassifikation. Hg. v. MVTec Software GmbH. www.mvtc.com/doc/halcon/1712/de/toc_deeplearning_classification.html, letzter Zugriff 12.02.2019.

Pan, S.-J., Yang, Q. (2010): A Survey on Transfer Learning. In: IEEE Transactions on Knowledge and Data Engineering.

Ribeiro, M.T., Singh, S., Guestrin, C. (2016): »Why Should I Trust You?«: Explaining the Predictions of Any Classifier. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery (KDD '16), 1135–1144. DOI: 10.1145/2939672.2939778, letzter Zugriff 04.02.2020.

Shwartz-Ziv, R., Tishby, N. (2017): Opening the Black Box of Deep Neural Networks via Information. <http://arxiv.org/pdf/1703.00810v3.pdf>, letzter Zugriff 30.01.2020.

Kontakt

Bastian Plaß, M.Sc. | Kira Zschiesche, M.Sc. |

Prof. Dr. Martin Schlüter

Institut für Raumbezogene Informations- und Messtechnik i3mainz,

Hochschule Mainz

Lucy-Hillebrand-Straße 2, 55128 Mainz

bastian.plass@hs-mainz.de | kira.zschiesche@hs-mainz.de |

martin.schlüter@hs-mainz.de

Tamer Altinbas, M.Sc.

tamer1992@web.de

Daniel Karla, M.Sc.

daniel.karla@web.de

Linda Rau, M.Sc.

Hochschule RheinMain

Postfach 3251, 65022 Wiesbaden

linda.rau@hs-rm.de

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