

SEGMENTIERUNG VON BETONRISSEN AUF BILDERN

PROJEKTZIEL

Infrastruktur muss zuverlässig auf Verschleiß überwacht werden. Manuelle Inspektionen sind kostspielig und nicht immer qualitätskonstant. Um zeitliche Veränderungen zu erkennen, müssen die Inspektionen regelmäßig gemacht werden und vergleichbar sein.

Fachleute in der strukturellen Zustandsüberwachung können von automatisierten Lösungen stark profitieren. Dieser Anwendungsfall demonstriert ein Deep Learning Werkzeug, das automatisch Betonrisse auf Pixelebene erkennen kann. Mit Hilfe einer solchen pixelweisen Klassifizierung (Segmentierung) können Risse hinsichtlich Breite und Höhe analysiert und über die Zeit verglichen werden.

VERWENDETES DATASET

Wir haben einen Datensatz von 458 hochauflösenden RGB-Bildern mit verschiedenen Betonrissen verwendet. Für jedes Bild wurde eine binäre Maske, die die Position des Risses anzeigt, als Label von Hand gezeichnet.

Die größeren Bilder wurden dann in kleinere Kacheln von 256 x 256 Pixel mosaikartig eingeteilt. Dadurch wurde eine konsistente Eingabegröße für das neuronale Netzwerk und eine überschaubare Speicherauslastung gewährleistet. Kacheln, die keine Risse enthielten, wurden entfernt, um das ohnehin schon große Ungleichgewicht im Verhältnis von gerissenen/nicht gerissenen Pixeln zu reduzieren. Insgesamt ergab sich daraus ein Datensatz von 12.310 beschrifteten Kacheln.

HERAUSFORDERUNGEN

Das Training eines neuronalen Netzwerks erfordert eine große Menge an Trainingsdaten. Die Erstellung der Pixelmaskenbeschriftungen ist eine zeitaufwändige Aufgabe. Die Label Qualität ist entscheidend für die Modelleistung.

Für verschiedene Anwendungen können die zu analysierenden Strukturen sehr unterschiedlich sein. Ein Modell, das ausschließlich auf Risse in glatten Betonoberflächen trainiert wird, wird sich nicht gut auf z.B. Asphalt- oder Ziegelwände verallgemeinern lassen. Gleiches gilt für die Lichtverhältnisse und Auflösungen der Eingangsdaten. Um diese Herausforderung zu meistern, haben wir umfangreiche Datenerweiterungen durchgeführt.



Bild und entsprechende Labelmaske
(3024 x 4032)




Input Kacheln (256 x 256)



Beispiele für die strukturelle Vielfalt für
verschiedene Anwendungen





Beispiele für Augmentationen

97%

*von allen Riss-Pixeln
wurden genau erkannt.*



Input, Ground Truth und Vorhersage

DATENANREICHERUNG

Unser Datensatz enthielt bereits eine Reihe von verschiedenen Oberflächen. Um die Leistung unseres Modells weiter zu steigern, haben wir verschiedene Augmentationstechniken eingesetzt, die verschiedene Lichtverhältnisse und strukturelle Abweichungen simulieren können. Augmentationstechniken, die wir mit zufällig durchgeführten Rotationen und Spiegelungen, veränderten Farbtönen, Sättigung und Helligkeit sowie zusätzlichen Rauschen und Mustern in den Eingabebildern verwendet haben. Die Datenvermehrung hat den Vorteil, das Risiko einer Overfittings zu reduzieren und kann die Modelleistung robuster machen. Dies stellt auch sicher, dass unser Ansatz mit minimalem Retraining auf ähnliche Fälle übertragen werden kann.

ANGEWANDTE METHODEN

Wir haben die neuronale Netzwerkarchitektur von Deep Lab v3 angewandt, den aktuellen Stand der Technik in der Bildsegmentierung. Das Modell und die Trainingspipeline wurden mit PyTorch implementiert.

Die Modelleistung wurde basierend auf dem Würfelkoeffizienten und der True Positive Rate (TPR) bewertet. Der erste gibt an, wie gut die vorhergesagten Crack-Pixel mit der Ground Truth übereinstimmen. TPR misst, wie viele Risspixel vom Modell genau erkannt wurden.

Das endgültige Modell erreichte einen Würfelkoeffizienten von 88% und einen TPR von 97% auf dem Validierungssatz. Diese Leistung ist für automatisierte Rissprüfanwendungen geeignet.

Vorhersagen wurden dann mittels morphologischer Öffnung entrauscht. Beim Zusammennähen der Fliesen konnten wir das gesamte Bild hinsichtlich der Anzahl der Risse sowie der Risslänge und -breite analysieren.

PROJEKTERGEBNIS

Das Werkzeug ist in der Lage, Oberflächenrisse auf Pixelebene genau zu erkennen. Rissbreite und -länge können so automatisch überwacht werden.

Für Anwendungen, bei denen Bilder durchgängig von den gleichen Stellen aufgenommen werden, ermöglicht dies die Analyse von Rissänderungen und die frühzeitige Erkennung neuer Risse.

MÖGLICHE ANWENDUNGEN

Unser Tool ist wertvoll für Fachleute in einer Reihe von Bereichen, die mit der strukturellen Zustandsüberwachung und der Instandhaltung der Infrastruktur arbeiten.

Bei neu gelabelten Daten eines Verteilergetriebes kann das Modell retrained und angewendet werden, um Risse in einer Reihe von Oberflächen wie Asphalt und anderen Betonstrukturen zu erkennen.

In Kombination mit geolokalisierten UAV-Bildern ist es möglich, mit diesem Ansatz eine vollautomatische Monitoring-Pipeline zu erstellen.

