

Deep Learning Analysen in ArcGIS - Hochrisiko-Waldbrandgebiete identifizieren und Waldbrandrisiken minimieren

Dr. Peter Saiger- Bonnas, Esri Deutschland GmbH

Herausforderung

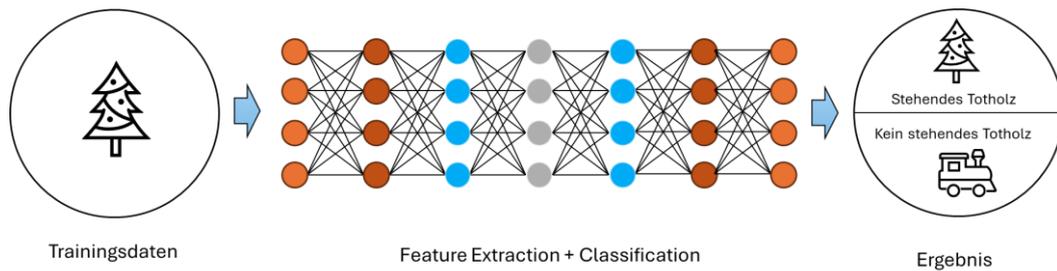
In Zeiten des Klimawandels mit der Zunahme von heißen und trockenen Tagen nimmt auch in Deutschland das Risiko von Waldbränden immer mehr zu. Deswegen müssen praxistaugliche Lösungen entwickelt werden, um möglichst effizient Waldflächen mit erhöhtem Waldbrandrisiko zu identifizieren und ggf. rechtzeitig präventiv Maßnahmen zum Schutz vor Waldbränden zu ergreifen.

Lösungsansätze

Immer häufiger sieht man am Himmel Flugzeuge, die in immer gleichen, wiederkehrenden Abständen fliegen. Dabei werden hochaufgelöste, sich überlappende Luftbilder aufgenommen, welche photogrammetrisch aufbereitet werden, um die Erdoberfläche sehr genau abzubilden. So sind beispielsweise flächendeckende Luftbilder mit einer Bodenauflösung von 2,5 cm pro Pixel keine Seltenheit mehr. Entscheidend ist hierbei auch aus Sicht des Waldbrandrisikos, wie aus diesen Daten Lösungen und Anwendungen entwickelt werden können, die zum Brandschutz in unseren Wäldern beitragen. So stellt sich die Frage, welche Flächen zu einem bestimmten Zeitpunkt ein erhöhtes Waldbrandrisiko aufweisen als andere Flächen. Indikatoren dafür können u.a. die Bodenfeuchte in Verbindung mit der Menge an Totholz sein. Immer bessere Aufnahme- und Prozessierungs-Technologien wie ArcGIS Reality in Verbindung mit Deep Learning Modellen können hier praxistaugliche Ansätze liefern.

Modellbeschreibung

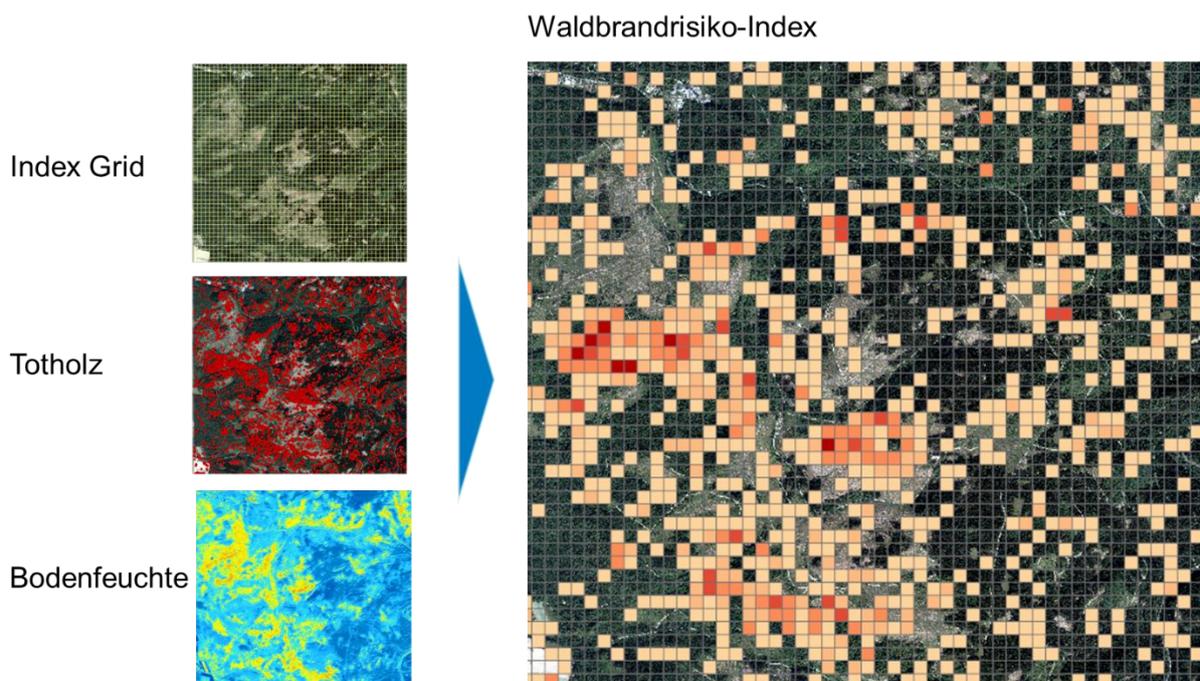
In der vorliegenden Untersuchung geht es um die Deep Learning gestützte Identifikation von Flächen mit erhöhtem Waldbrandrisiko auf Basis der Indikatoren stehendes Totholz und Bodenfeuchte. Der Ansatz wurde auf einer Fläche im Nordharz in Abstimmung mit den niedersächsischen Landesforsten durchgeführt. Mit der Image Analyst Erweiterung für ArcGIS Pro bietet Esri die Möglichkeit, eigene Deep Learning Modelle zu erstellen, zu trainieren, anzuwenden und zu validieren. Hierbei werden in einem ersten Schritt Trainingsdaten erstellt, um aus den Luftbildern Totholz mengen abzuleiten. Da es sich um ein einfaches Modell handelt, also toter Baum oder nicht, lässt sich das Modell mit einer einzelnen Klasse erstellen. Für den Trainingsdatensatz werden repräsentative tote stehende Bäume, über das komplette Analysegebiet verteilt, markiert. In einem nächsten Schritt wird das Modell mit den manuell markierten toten Bäumen trainiert. In der ArcGIS Image Analyst Erweiterung stehen die gängigsten Deep Learning Frameworks zur Objekterkennung wie beispielsweise Single Shot Detector, YOLOv3, etc. zu Verfügung.



Nachdem das Modell zur Erkennung toter stehender Bäume trainiert wurde, kann es auf die gesamten Bilddaten angewendet werden, um danach das Ergebnis nochmal zu bereinigen. Dazu zählen beispielsweise sich überdeckende positive Identifizierungen oder schattenspezifische Ereignisse. Dies lässt sich mit Standard Tools auch weitgehend automatisieren. Am Ende der Auswertungen können dann mit hohen Wahrscheinlichkeiten Flächen mit vermehrtem stehenden Totholzanteil ausgewiesen werden.

Die Daten zum stehenden Totholz werden dann um den NDMI aus Sentinel-Daten ergänzt, um so dann mit zonal statistics den Mittelwert der Summe aller Pixel in einem Testfeld von 1 ha (Index grid) die Bodenfeuchte abzuleiten. Die Kombination aus geringer Bodenfeuchte und erhöhtem Totholzaufkommen kann auf eine erhöhte Waldbrandgefahr hinweisen. Zumindest könnte man auf solche Flächen ein erhöhtes Augenmerk legen.

Um vor der Lage zu sein, muss Pragmatismus gegen Wissenschaft abgegrenzt werden. Denn bei Kalamitäten wie Borkenkäfer ist die Geschwindigkeit der entscheidende Faktor. Klar ist der einzeln befallene Baum eine neue Quelle für die weitere Ausbreitung, jedoch steht in diesem Modell die Waldbrandgefahr durch Totholz hier im Fokus.



Zusammenfassung

Das Innovationspotenzial von immer hochauflösenderen Luftbildern in Verbindung mit Methoden zu Deep Learning ist neben anderen Anwendungsmöglichkeiten wie in der Forsteinrichtung für das Totholzmanagement oder die Waldbrandüberwachung hoch. Jedoch fehlen nach wie vor standardisierte und praxistaugliche Tools, die Förster in ihrer täglichen Arbeit nutzen können. Diese Auswertung soll einen Ansatz zur Diskussion bieten, wie aus Deep Learning Modellen abgeleitete Anwendungen für die Praxis einsetzbar sind. Neben Revierleitern, Forstamtsleitern oder Rangern können solche Anwendungen auch für die Feuerwehr, die Bundesimmobilienverwaltung oder dem Katastrophenschutz sinnvoll sein.