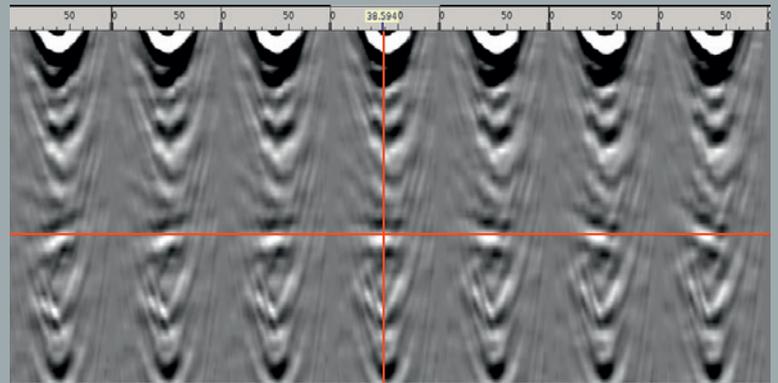


1



2

BOULDER-DETECTION MIT MACHINE LEARNING

1 Ausschnitt aus dem aus seismischen Daten errechnetem Untergrundabbild; Farbspots zeigen Orte hoher Wahrscheinlichkeit für das Vorliegen von Felsbrocken an.

2 Illuminationsdarstellung eines Untergrundbereiches, für den ein Felsbrocken identifiziert wurde; das Fadenkreuz liegt im Symmetriezentrum des identifizierten Musters und zeigt die laterale Position des Felsbrockens in 73 m Tiefe an.

Die Pfeiler der Windräder von Offshore-Windparks müssen tief in den Schichten unterhalb des Meeresbodens verankert werden. Große Gesteinsbrocken stellen dabei Hindernisse dar, die man vorab erkennen muss, um die exakte Positionierung der Windräder zu planen. Die seismischen Datensätze, die zur allgemeinen Standsicherheitsbestimmung gemessen werden, reichen hier nicht aus. Mit neuen Machine Learning-Methoden können wir Muster im Untergrund schneller detektieren und klassifizieren.

Bisherige Auswerteverfahren der seismischen Datensätze enthüllen zwar die Gesteinsschichtungen des Untergrundes, weisen allerdings einen zu geringen Frequenzgehalt auf, um Felsen im Bereich von 1 m Durchmesser als reflektierende Objekte erkennen zu können. Deshalb müssen die Amplitudenschwachen Diffraktionsantworten ausgewertet werden.

Mustererkennung in Untergrundabbildungen

In einem vom Bundesministerium für Wirtschaft und Energie geförderten Projekt haben wir mit Kollegen vom Fraunhofer-Institut für Windenergiesysteme IWES einen Prozess entwickelt, der diese Diffraktionen in ein typisches Muster in seismischen Untergrundabbildungen überführt. Die Aufgabe, diese Muster oder Diffraktionsobjekte zu erkennen, ist vergleichbar mit der Zuweisung von Pixeln in Photographien zu Objektklassen, wie sie mithilfe tiefer neuronaler Netze möglich ist.

Unser Anwendungsfall beinhaltet ein wesentlich höher-dimensionales Problem, da bereits bei 2D-Untergrundabbildungen zwei weitere Dimensionen hinzukommen: die Beleuchtungsrichtung und die Abhängigkeit vom für die Bilderstellung verwendeten Geschwindigkeitsmodell. Des Weiteren ist der Erduntergrund nicht der direkten Anschauung zugänglich, sodass die Netzwerke anhand realistisch verfremdeter synthetischer Daten trainiert werden müssen.

Anwendernutzen: Reduzierte Datenmenge

Die Anwendungsergebnisse zeigen, dass das Transfer-Learning von synthetischen zu realen Daten gelingt und dass unsere aus einer Vielzahl von Convolutions-Schichten bestehenden Netzwerke die notwendige Komplexität aufweisen, um auch in verrauschten Untergrundabbildungen Wahrscheinlichkeiten für das Vorhandensein von Störobjekten mit einer räumlichen Auflösung von 1 m zu errechnen. Der Nutzen für den Anwender ergibt sich damit aus der erheblichen Reduktion der Menge an Daten aus dem gesamten hoch-dimensionalen Datensatz, die er selbst interpretieren muss.