

# Tief lernen lassen

Franziska Konitzer

■ Ein bisschen KI, sehr viel Klassifikation, keine Katzenbilder: Deep Learning Verfahren helfen inzwischen auch Geodäten und kommen vor allem in der Photogrammetrie und in der Fernerkundung zum Einsatz.

Während sich einerseits einige Menschen Gedanken darüber machen, ob uns die künstliche Intelligenz, kurz KI, den Rang ablauft, jetzt, da sie nicht nur die weltbesten Go-Spieler und eSportler der Welt schlägt, sondern schon längst Handschriften, Sprachen und Katzenbilder zuverlässig erkennen kann, stellt sich andererseits immer noch die Frage, wie die zugrunde liegenden Deep Learning Verfahren eigentlich funktionieren und was Menschen, vor allem Geodäten, mit ihnen Sinnvolles anstellen können.

## Ein Klassenlabel für jedes Pixel

Für Christian Heipke vom Institut für Photogrammetrie und GeoInformation der Leibniz Universität Hannover ist die Frage nach dem Sinnvollen recht schnell beantwortet: »Deep Learning kann überall da eine Rolle spielen, wo man Bilder interpretieren möchte.« Aus Sicht der Aufgabenstellungen in der Geodäsie ist das zunächst vor allem bei der Erkennung von Landbedeckung und Landnutzung aus der Luft der Fall. So lassen beispielsweise die verschiedenen Landesvermessungsämter regelmäßig Luftbilder erstellen. Ein Pixel deckt dann zum Beispiel fünf mal fünf Quadratzentimeter Fläche ab, die je nachdem ein Stückchen Feld, Baum, Hausdach oder Straßen enthalten kann.

Wenn man nicht möchte, dass ein Mensch jedes Pixel einzeln klassifiziert und die Landbedeckung händisch festlegt, können inzwischen Deep Learning Verfahren zum Einsatz kommen. »Man will für jedes Pixel ein Klassenlabel«, erklärt Franz Rottensteiner, ebenfalls vom Institut für Photogrammetrie und GeoInformation der Leibniz Universität Hannover, anders ausgedrückt: Der Computer sollte selbst erkennen, was auf dem Bild zu sehen ist.

Laut Ribana Roscher von der Universität Bonn sind Deep Learning Verfahren aber auch gut darin, räumliche Muster auszumachen. »Bei Landnutzungs- und Landbedeckungsklassifikationen vom Satelliten aus nutzt man bislang oft sogenannte Composite, also aufwendig zusammengesetzte Bilder, die aus vielen Aufnahmen über einen Zeitraum von mehreren Wochen oder sogar Monaten entstehen«, erklärt sie. »Composite sind notwendig, da in den einzelnen Aufnahmen die Wetterbedingungen natürlich nicht immer ideal sind. Mit Deep Learning wird dies einfacher, denn der Algorithmus kann beispielsweise selbst lernen, dass Wolken nicht wichtig sind.«

## Die verborgenen Schichten von Deep Learning

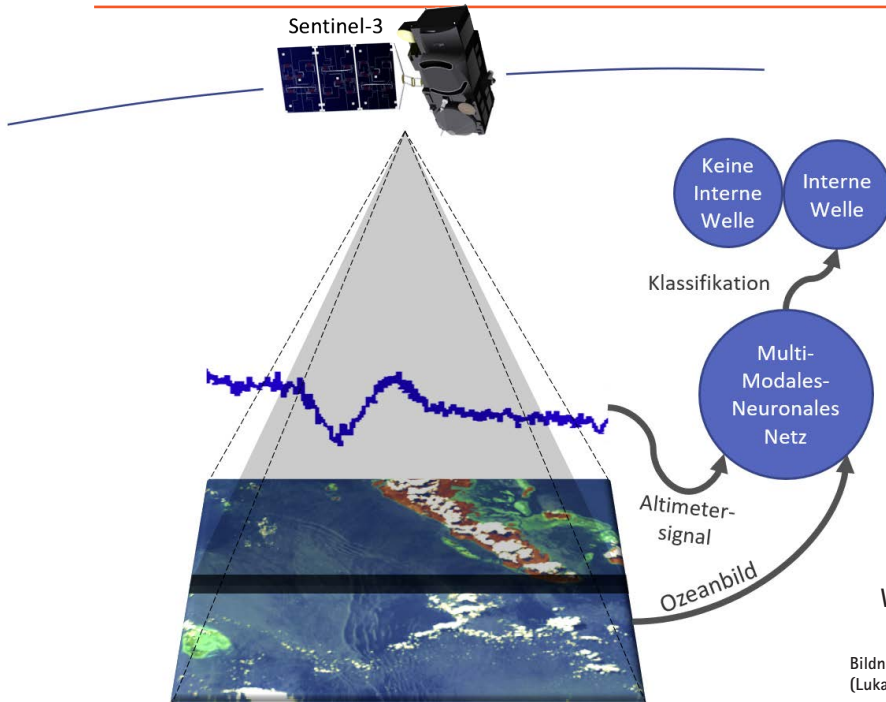
»Prinzipiell operiert Deep Learning mit künstlichen neuronalen Netzen«, erzählt Franz Rottensteiner. Das Erstaunliche daran ist: Obwohl KI im Allgemeinen und Deep Learning Verfahren als eine Variante dessen derzeit in aller Munde – und aller Computer – sind, ist die Idee der neuronalen Netze tatsächlich ziemlich alt. Bereits in den 1940er-Jahren versuchten sich Wissenschaftler daran, die Funktionsweise einer Nervenzelle, Neuron genannt, nachzubauen. »Aber ein einzelnes Neuron kann nur sehr einfache Aufgaben lösen«, so Rottensteiner.

Bei den heutigen Verfahren kommen deshalb tausende Neuronen in mehreren Schichten zum Einsatz. Ein derartiges Netz verfügt über eine erste, sogenannte Input-Schicht, sowie am Ende eine Output-Schicht, die hoffentlich die gewünschten Antworten liefert. Dazwischen befindet sich das »deep« des Deep Learnings: die sogenannten »hidden layers«, die verborgenen Schichten, welche die eigentliche Klassifikation des Inputs Schritt für Schritt und Schicht für Schicht vornehmen. Moderne Deep Learning Verfahren können über hundert solcher Schichten aufweisen. Das »learning« im Deep Learning bezeichnet die Tatsache, dass der Algorithmus letztendlich selbst lernt, wie er etwas erkennt. Als Beispiel kann ein Ahornblatt dienen, beziehungsweise das Bild eines Ahornblatts.

»Vor Deep Learning hatten wir klassische Mustererkennung, die genau dasselbe versucht hat«, sagt Christian Heipke. Bei dieser musste sich der Benutzer vorher überlegen, anhand welcher Merkmale der Algorithmus das Ahornblatt als Solches erkennen sollte. Welche Farbe hat es? Wie viele Zacken weißt es auf? Ist der Blattrand glatt oder gezähnt? »Deep Learning hingegen lernt durch Beispiele«, so Heipke.

Der Benutzer trainiert also den Algorithmus, indem man ihm das Bild eines Ahornblatts zeigt und ihm sagt, dass es sich dabei um ein Ahornblatt handelt. Und dann noch eins. Und noch eins. Und noch eins. Tausende Bilder von Ahornblättern. »Die Trainingsbeispiele, die man dem Computer zeigt, sind die Grundmenge dessen, was gelernt werden kann«, sagt Heipke. Das heißt, dass auch das beste Deep Learning Verfahren kein rotes Ahornblatt als solches erkennen kann, wenn es vorher noch nie etwas anderes als grüne Ahornblätter gesehen hat. »Aber was ich nicht machen muss, ist, mir vorher zu überlegen, wie ein Ahornblatt eigentlich aussieht«, sagt Heipke.

Das mag nach einem konstruierten Beispiel klingen, ist es aber nicht. Gerade in der Luftbildauswertung von Landbedeckung ist es laut Franz Rottensteiner schwer, richtig allgemeine Datensätze zum Trainieren zu bekommen. Hausdächer im Süden Deutschlands sehen anders aus als im Norden des Landes. Jahreszeiten spielen



Ein Deep Learning Verfahren kann lernen, riesige Unterwasserwellen im Meer aufzuspüren. Dafür werden optische Satellitendaten, also Bilder, mit Radardaten kombiniert. Die Output-Schicht des Algorithmus besteht aus zwei »Neuronen«, die je eine Wahrscheinlichkeit liefern, ob es sich bei der Beobachtung um eine derartige interne Welle handelt oder nicht.

Bildnachweis: »Multi-Modal Deep Learning for Sentinel-3 Observations« (Lukas Drees, 10/2019)

eine Rolle. Manchmal gibt es Schlagschatten, manchmal nicht. Um einen Deep Learning Algorithmus perfekt zu trainieren, müsste man ihm alles zeigen.

»Diese Verfahren sind ziemlich datenhungrig«, sagt Franz Rottensteiner. Tatsächlich ist das einer der Gründe, warum es mehrere Jahrzehnte gedauert hat, bis das Verfahren nun inzwischen seinen Hype erlebt. Denn Jahrzehnte lang wurden neuronale Netze und Deep Learning von einem Mangel an Trainingsdaten geplagt, sowie von zu langsamen Rechnern und einigen algorithmischen Komplikationen. »Die ganzen neuronalen Netze waren Anfang der 2000er-Jahre eigentlich tot«, erzählt Rottensteiner. »Der Durchbruch kam erst 2012.«

### Von Computer Vision hin zur Geodäsie

2012 gewann ein Deep Learning Verfahren namens AlexNet die sogenannte ImageNet Large Scale Visual Recognition Challenge, bei der verschiedene Algorithmen gegeneinander antreten, um Bilder aus einer Datenbank mit Millionen Aufnahmen zu erkennen. Möglich gemacht hatten dies einige Verbesserungen im Algorithmus an sich. Aber vor allem die bessere Verfügbarkeit von Trainingsdaten – sprich Bildern, die sich das Verfahren anschauen kann – sowie mehr Rechenleistung machten diesen Erfolg möglich. Statt auf Kernprozessoren, den CPUs, rechnete AlexNet auf Grafikkarten. Zwar können die Trainingszeiten immer noch bei Wochen liegen, aber spätestens seit 2012 haben Deep Learning Verfahren ihren Siegeszug angetreten, denn sie funktionieren sehr gut, fast durchweg besser als klassische Verfahren.

»Wo wir vorher 80 Prozent Erfolgsquoten bei der Klassifizierung hatten, haben wir jetzt bis zu neunzig Prozent«, sagt Rottensteiner. »Natürlich ist das mit den Hunde- und Katzenbildern aus der ImageNet Challenge für uns Geodäten irrelevant. Aber wir haben stattdessen Luftbilder, Satellitenbilder, manchmal auch Höhendaten.«

Auch für Ribana Roscher spielen die Aufgaben aus der Computer Vision, also dem reinen Erkennen von digitalisierten Bildern durch einen Algorithmus, keine so große Rolle. Sie geht sogar noch einen Schritt weiter, über die Bilder von photogrammetrischen Verfahren hin zu weiteren Arten von Fernerkundungsdaten. Denn prinzipiell sind Deep Learning Verfahren als Ansatz natürlich nicht auf das Klassifizieren und Interpretieren von RGB-Werten, also dem Rot-, Grün- und Blauanteil, in Pixeln beschränkt. So kombiniert Roscher beispielsweise optische Satellitendaten mit Radardaten der Fernerkundung. Bilder und Radarsignale werden also zeitgleich zusammen ausgewertet, beispielsweise, um riesige Unterwasserwellen in Meeren aufzuspüren, die erheblich die U-Boot Navigation stören. »Das nennt sich multimodales Lernen«, sagt sie. »Da funktioniert Deep Learning richtig gut.«

In einem weiteren Schritt würden Wissenschaftler wie Roscher die »Black Box« der Deep Learning Verfahren gerne einen Spalt weit öffnen. Sie wollen ihren trainingsbasierten Ansatz gerne mit wissensbasierten Modellen verknüpfen. In so einem Fall müsste der Algorithmus nicht mehr alle Ahornblätter in sämtlichen möglichen Zuständen selbst »sehen« und lernen, sondern man könnte ihm auch einfach sagen, dass sich Ahornblätter im Herbst verfärben, bevor sie schließlich vom Ast fallen. Einen solchen Ansatz könnte man bei Erntevorhersagen einsetzen. »Wir wollen in der Fernerkundung ja keine Hunde und Katzen erkennen, sondern biochemische und geophysikalische Größen ableiten«, sagt Roscher. »Und darüber haben wir ja bereits Vorwissen. Das wäre dann informed deep learning.«

An diesem Punkt ist man zwar noch nicht, derzeit arbeiten die existierenden Verfahren ziemlich isoliert. Aber Wissenschaftler arbeiten daran, ihren Algorithmen etwas beizubringen, damit diese anschließend besser selbst lernen können.

Kontakt: f.konitzer@gmail.com