

Modelle für Korrespondenzfindung und probabilistisches repräsentatives Lernen

Kurzfassung der Dissertation von Christian Keck

Die Arbeit beschäftigt sich mit der Modellierung und Untersuchung von neuronalen Netzwerken. Aufgaben, die wir Menschen täglich spielend bewältigen, sind aus Sicht der Informationsverarbeitung sehr komplexe Aufgaben, die zum heutigen Stand von Algorithmen nur mit sehr viel Aufwand und meist in engen Rahmenbedingungen gelöst werden können. Menschen lernen als Kinder die visuellen Eindrücke Ihrer Umwelt zu interpretieren und sich in dieser Umwelt zu bewegen. Um sich in seiner Umwelt zurechtzufinden, muss ein Mensch Objekte erkennen, und bevor er das kann, muss er lernen, welche Objekte es gibt und wie sie aussehen. Die Objekterkennung und insbesondere das Lernen von Objektrepräsentationen ist Schwerpunkt dieser Arbeit.

Im ersten Teil der Arbeit wird ein künstliches neuronales Netzwerk, das ein Modell kortikaler Kolumnen als Entscheidungseinheiten nutzt, für die translationsinvariante Erkennung eines Objektes untersucht. Simulationen des Netzwerks mit natürlichen Bildern als Input ergaben, dass das vorgestellte Netzwerk in der Lage ist, ein gegebenes Objekt in einem anderen Bild translationsinvariant zu erkennen. Außerdem zeigen die Ergebnisse, dass das System robust gegen geringe andere Objekttransformationen wie beispielsweise Rotation, Verzerrung und Beleuchtung ist. Für die beschriebenen Simulationen wurden Verbindungen innerhalb des neuronalen Netzwerks, die die Nachbarschaft innerhalb eines zweidimensionalen Gitters repräsentieren, von Hand erstellt. Anschließend soll herausgefunden werden, ob ähnliche Verbindungen auch durch Lernen innerhalb des gleichen neuronalen Netzwerks entstehen können. Es wird eine auf Nachbarschafts-Korrelationen basierende Lernregel entwickelt. Dem Netzwerk werden zum Lernen benachbarte Bildausschnitte zusammen mit zufällig angeordneten Bildausschnitten präsentiert. Das Netzwerk lernt dabei die Ähnlichkeit von Bildeigenschaften und die Nachbarschaft von Bildeigenschaften zu integrieren. Die numerischen Versuche wurden hier wiederum bzgl. Translationsinvarianz durchgeführt, andere Transformationen sind aber mit der gleichen Methodik lernbar, sofern die Vorverarbeitung der Daten angepasst wird. Die Ergebnisse zeigen sowohl qualitativ als auch quantitativ (Lernkurven und Fehlerraten), dass das beschriebene Netzwerk fähig ist, die nötigen Verbindungen unüberwacht aus den präsentierten Daten zu lernen.

Der zweite Teil der Arbeit beschäftigt sich mit dem Vergleich des Lernens zwischen einem neuronalen Netzwerk, bestehend aus einzelnen Neuronen, und einem probabilistischen Modell. Während das neuronale Netzwerk seine Gewichte nach jedem Datenpunkt anpasst und somit 'online' von iterativ präsentierten Daten lernt, werden für das Lernen der Parameter des probabilistischen Modells Update-Gleichungen für einen EM-Algorithmus hergeleitet und implementiert. Der EM-Algorithmus arbeitet im sogenannten 'Batch'-Modus, er arbeitet auf allen Datenpunkten gleichzeitig.

Beide Algorithmen lernen unüberwacht, zunächst aus künstlichen Daten und anschließend aus natürlicheren Daten (handgeschriebene Ziffern der MNIST Datenbank). Es wird analytisch und in numerischen Experimenten gezeigt, dass beide Modelle zu den gleichen Fixpunkten konvergieren. Für die numerischen Experimente werden hierzu qualitativ die gelernten Gewichte des neuronalen Netzwerks mit den Parametern, zu denen der EM-Algorithmus konvergiert ist, verglichen. Außerdem werden die Ergebnisse quantitativ mit Hilfe der Log-Likelihood verglichen.

Um einen weiteren Aspekt des Vergleichens zu ermöglichen, werden die gelernten Parameter mit Hilfe eines zusätzlichen überwachten Lernens für die Klassifizierung von neuen Datenpunkten genutzt. Für die Klassifizierung müssen die gelernten Felder den möglichen Klassen zugeordnet werden, dies wird mit Hilfe eines probabilistischen Ansatzes durchgeführt.

Auch die Ergebnisse der Klassifizierung der MNIST-Daten zeigen, dass sich die Algorithmen sehr ähnlich verhalten. Außerdem zeigen numerische Experimente, in denen alle Datenpunkte für das unüberwachte Lernen, aber nur wenige für den zweiten Schritt, das überwachte Lernen, verwendet werden, eine bemerkenswert hohe Klassifizierungsrate. Dieses Ergebnis ist besonders interessant für Anwendungen, für die Daten per Hand ihrer Klasse zugeordnet werden, da sich dieser Arbeitsaufwand mit Hilfe eines solchen zweistufigen Algorithmus verringern lässt.