

Algorithmic Bias and Fairness

SS 22

Teilnehmer: Tom Sühr, Josef Pelz

Kurzbeschreibung

Algorithmen finden längst in nahezu jedem Lebensbereich Anwendung. Insbesondere werden sie zur Entscheidungsfindung und in Empfehlungssystemen eingesetzt. Häufig werden dabei **künstliche neuronale Netzwerke (NN)** verwendet. Diese werden beispielsweise auf existierenden Datensätzen trainiert und angewendet um neue Datenpunkte gewissen Klassen zuzuordnen (Klassifizierung). Hierbei hat die Wahl der Datenbank, etwa die verwendeten Eigenschaften (Features) einzelner Datenpunkte, und der Aufbau/ die Architektur des NN großen Einfluss auf die Ergebnisse. Es ist daher wichtig, dass sowohl die Entwickler:innen als auch die Nutzer:innen dieser Systeme sich die Frage stellen: „Wie Gerech sind diese Algorithmen?“.

Ziel des Projekts „Algorithmic Bias and Fairness“ (Algorithmische Vorurteile und Gerechtigkeit) ist es, die Relevanz und Komplexität dieser Frage greifbar zu machen. Zukünftige Entscheidungsträger:innen sollen einen kritischen Blick auf die Anwendung schwer durchschaubaren neuronalen Netzwerke erlangen. Als Medium der Kommunikation haben wir uns für eine interaktive Webseite entschieden. Nutzer:innen können anhand von Beispielen nachvollziehen wie bestehende Strukturen in Datenbanken zu Diskriminierung führen und hinterfragen, wie sie solche Algorithmen nutzen.

Umsetzung

Um möglichst vielen Menschen die Auseinandersetzung mit der Thematik zu ermöglichen, haben wir uns für eine Website als Medium entschieden. Die potentielle Reichweite ist groß und die Verknüpfung mit anderen Webseiten via Hyperlinks ermöglicht es Nutzer:innen, je nach Vorwissen und Interesse, auf grundlegenderes oder tiefergehendes Wissen zuzugreifen. Zusätzlich können wir mittels JavaScript und WebGL eine interaktive Erfahrung kreieren, die eine spielerische Auseinandersetzung möglich macht und ein intuitives Verständnis vermitteln kann.

Der Einstieg in die Webseite ist ein Einstieg in die Thematik und bietet einen schnellen Überblick. Mehrere Links bieten Zugang zu Hintergrundwissen an. Beispiele von Anwendungsbereichen Neuronaler Netzwerke stellen deren Relevanz dar und verdeutlichen: Die von einem Algorithmus getroffenen Entscheidungen sollten so fair wie möglich sein.

Darauffolgend werden Kriterien für Fairness eingeführt und Ansätze präsentiert um diese zu einzuhalten. Um die grundlegende Funktionsweise Neuronaler Netzwerke zu erläutern und zu verdeutlichen, weshalb einige der Ansätze nicht geeignet sind, führen wir ein interaktives Beispiel heran.

Auf einer zweidimensionalen Fläche sind Datenpunkte einer Datenbank abgebildet, angeordnet nach zwei Eigenschaften/Features. Jeder Datenpunkt ist entweder als Kreuz oder als Kreis markiert. Dies stellt die Zugehörigkeit zu einer Gruppe oder Klasse da. Nutzer:innen werden aufgefordert, eine Linie durch die Datenmenge zu ziehen, die so gut wie möglich Kreuze von Kreisen trennt. Aufgrund der Datenlage ist dies nicht fehlerfrei möglich. Das ist zwar zu erwarten, die Frage ist jedoch auf Kosten

vom wem die Fehler gemacht werden. Im nächsten Schritt wird eine weitere, soweit unbekannte Klasse durch Farbgebung sichtbar. Datenpunkte gehören nicht nur zur Klasse Kreuz oder Kreis, sondern zusätzlich auch entweder zu Gelb oder Blau. Es wird ersichtlich, dass die meisten Fehler bei Datenpunkten der Gruppe Gelb gemacht wurden. Es wird dadurch klar, dass wir unabsichtlich und unwissend diskriminieren können.

Technische Details

From: <http://www.labprepare.tu-berlin.de/wiki/> - Project Sci.Com Wiki

Permanent link: http://www.labprepare.tu-berlin.de/wiki/doku.php?id=algorithmic_bias_and_fairness&rev=1665489612

Last update: 2022/10/11 14:00

