

Studiengang Sustainable Energy Competence (SENCE)

STUDIENARBEIT

Forschungsprojekt 2

**Neuronale Netze
im Bereich der Strombedarfsvorhersage für Gebäude**

Robert Otto



Vorgelegt durch: Robert Otto
Adresse: Klopstockstraße 33b 70193 Stuttgart
Datum: 22.10.2018

Erstprüfer: Dr. Dirk Pietruschka
IAF Hochschule für Technik Stuttgart
Hochschule für Technik Stuttgart
Schellingstraße 24
70174 Stuttgart

Zweitprüfer: Dieter Ebinger
Enisyst GmbH
Robert-Bosch-Str. 8/1
72124 Pliezhausen

Erklärung

Ich versichere hiermit, dass ich die vorliegende Arbeit selbständig angefertigt und dabei nur die in der Arbeit ausdrücklich genannten Hilfsmittel und Quellen verwendet habe.

Stuttgart, den 22.Oktober 2018



Zusammenfassung

Künstliche neuronale Netze gehören in das Themengebiet der künstlichen Intelligenz und stellen eine mathematische Nachbildung von Nervenzellen dar, die durch einen Informationsfluss Entscheidungen bzw. Erkenntnisse wiedergeben können. Diese dienen dabei hauptsächlich der Effizienzsteigerung der menschlichen Umgebung und schaffen somit Erleichterungen im Alltag. Aktuelle Beispiele sind Suchmaschinen bzw. Programme die aufgrund von Mustern, Daten zuordnen können.

Die kognitive Leistung von Lebewesen unterscheidet sich gegenüber der Rechenleistung eines Computers im Bereich der Anwendung. Computer arbeiten hierbei in der Regel einen Algorithmus ab und geben ein exaktes Ergebnis aus. Beschränkt man dies auf die binäre Maschinensprache entspricht das Ergebnis Eins und Null, was auch als an und aus definiert werden kann.

Die Ausgabe, die bei einem natürlichen neuronalen Netzwerk stattfindet wird jedoch nicht zwischen Eins und Null beschränkt. Es findet eine Abwägung aufgrund Erfahrungswerte statt, durch die eine Entscheidung getroffen wird. Um an diese Erfahrung zu gelangen muss eine Situation bereits durchlebt worden sein. Dieser Vorgang wird auch allgemein als Lernen definiert. Diese Abwägung kann nun auch dazu dienen eine Prognose zu stellen um somit Prozesse effizienter zu betreiben. Dabei geht es vor allem um eine Leistungssteigerung sowie um die Senkung von Sicherheitsrisiken. Solche Programme werden schon in einigen Gebieten erfolgreich verwendet. Ein bekanntes Beispiel ist hierfür der Übersetzungsdienst von Google. Der Übersetzer arbeitet mit einem neuronalen Netz, das ganze Sätze mit hinterlegten Daten vergleicht und dementsprechende übersetzt.

Bei neuronalen Netzen spielen dabei die Eingangsdaten eine zentrale Rolle. Reichen die Informationen nicht aus, bzw. werden diese nicht richtig verarbeitet können die Netzwerke keine gute Prognose ausgeben. In dieser Arbeit wird dabei untersucht, ob ein neuronales Netzwerk mit relativ oberflächlichen Inputs eine Prognose für den Nutzerstrombedarf ausgeben kann. Das Problem hierbei ist, dass keinerlei Nutzerdaten dem Netz zur Verfügung stehen, wodurch es nur mittels der Konstellation von Wetter und Zeit auf den Nutzerstromverbrauch schließen soll.

Die Ergebnisse dieser Untersuchung zeigen, dass ein neuronales Netz tatsächlich ein Potential aufweist, was die Vorhersage des Strombedarfs eines Mehrfamilienhauses angeht. Jedoch muss hierbei beachtet werden, dass es sich um ein lernendes System handelt, dass aufgrund von Zusammenhängen ein Ergebnis ausgeben kann.

So stellt das Basis-Netz die Grundvariante dar. Sie wird mit nicht bereinigten Daten trainiert und auch getestet, da ein lernendes System schließlich auch Fehler erkennen sollte. Das Ergebnis hierbei ist eine äußerst niedrige Korrelation mit einem Pearson Korrelationskoeffizient von 0,26 und einer maximalen Abweichung von 417% und -81%. Die mittlere Abweichung fällt hierbei wesentlich geringer aus, so beträgt diese 44% und -27%. Die weiteren Untersuchungen dienen der Optimierung, wodurch Veränderungen an den Parametern mittels iterativer Schritte betrachtet werden und ob sich somit ein stabiles Netz generieren lässt. Die optimierten Netze können hierbei einen Korrelationskoeffizienten von bis zu 0,51 erreichen, jedoch ist die mittlere Korrelation bei 100 Durchläufen relativ gering.

Bildet man aus allen Iterationen den arithmetischen Mittelwert, so ergeben sich im Durchschnitt Werte von 0,24 bis 0,37. Diese stellen somit kein stabiles Netz dar, da die Differenz zwischen dem Maximal- und dem Mittelwert viel zu groß sind. Bei stabilen neuronalen Netzen, wie beispielsweise bei dem MNIST-Test oder dem Sinustest, stellen

sich Korrelationen von ca. 0,95 und 0,99 ein. Durch ein erneutes Training kann sich auch hier die Korrelation ändern, jedoch beträgt diese Differenz, je nach Test zwischen 0,01 und 0,001. Durch weitere Testreihen lässt sich die optimale Konstellation der Parameter ermitteln. Die maximale Korrelation in dieser Testreihe beträgt 0,48 mit einer mittleren Korrelation 0,41. So stellt diese Variante schon ein wesentlich stabileres neuronales Netz dar. Um die maximale Korrelation zu erhöhen werden die Testreihen mit bereinigten Trainings- und Testdaten durchgeführt. Die Ergebnisse sind deutlich schlechtere maximale und mittlere Korrelationen. So werden für die maximale und die mittlere Korrelation Werte von 0,41 und 0,37 ausgegeben. Da für diese Testreihe die Inputdaten bereinigt sind und somit der Lern-Input aufgrund von verkleinerten Trainingsdaten sinkt, werden die Trainingsdaten um das bereinigte Jahr 2016 verlängert. Dadurch steigt der Trainingsinput und das neuronale Netz könnte der Theorie nach Zusammenhänge besser lernen, jedoch weist diese Testreihe keine wesentlichen Verbesserungen zum Basis-Netz auf.

In einer weiteren Variante wird untersucht, inwiefern die Vorhersage des neuronalen Netzes verbessert werden kann, wenn eine Strombedarfsprognose als Input-Datei verwendet wird. Hierfür kann das H0-Stromlastprofil für Haushalt verwendet werden. Die Ergebnisse dieser Untersuchung zeigen, dass relative hohe maximale und mittlere Korrelationen erreicht werden. Die Netze sind in allen Bereichen wesentlich stabiler und weisen teilweise eine maximale und mittlere Korrelation von 0,53 und 0,47 auf. Im direkten Vergleich fällt außerdem auf, dass die Vorhersage des Netzes gegenüber den tatsächlichen Werten sich im Verlauf ähneln und annähern. Durch die Implementierung der Prognose weist das neuronale Netzwerk bei dieser Variante immer noch hohe maximale Abweichungen von 205% und -74% auf. Die mittlere Abweichung sinkt auf 31% und -24%. Jedoch stellen diese gegenüber dem Basis-Netz eine wesentliche Verbesserung dar.

Damit ist jedoch auch klar, dass die bisherigen Inputs als Datenbasis nicht reichen. So sollten auch weitere Informationen verwendet werden, die auf die Stromnutzung schließen lassen. Als zusätzliche Information wäre eine Art Nutzerprofil sinnvoll, da dies dem neuronalen Netz einen größeren Zusammenhang zwischen Stromverbrauch und Anwesenheit der Bewohner suggerieren kann. Das Netz könnte sich an diesem orientieren und somit wahrscheinlich eine bessere Prognose für Lastspitzen generieren.

So wäre es sinnvoll, Nutzerprofile zu verwenden, die entweder leicht zu erfassen sind oder zum Teil schon bestehen. Hierfür wären beispielsweise die Einschaltquoten beim Fernsehen eine interessante Datenquelle, die somit als Input verwendet werden könnten. Ebenfalls interessant und als Nutzerprofil möglich wäre die Datenmenge, die mit dem Internet ausgetauscht wird. Anhand ihrer Struktur könnte man erkennen wann ein Nutzer zuhause ist und wann er vermeintlich Energie konsumiert.

Neuronale Netze oder auch andere Werkzeuge aus dem Gebiet der künstlichen Intelligenz könnten mit dieser Information außerdem Prognosen über den Wärme- und Trinkwarmwasserbedarf geben und wären damit ein entscheidender Meilenstein für die Energiewende.