

Smart Grid LAB Hessen
WHITE PAPER

Smart-Grid-KI: Machine- Learning bei Smart-Grid Anwendungen

7. Juli 2022
TRACTEBEL ENGINEERING GMBH
DR. LUCA PIZZIMBONE



EUROPEAN UNION
Investing in Your Future
European Regional
Development Fund



HESSEN
Ministry for Economic Affairs,
Energy, Transport and Housing
State of Hessen



1 Einleitung

Wer hat nicht schon einmal davon geträumt, eine Methode zu finden, mit der man die Zukunft vorhersagen, die Ungewissheit abmildern und weise Informationen erhalten kann, um sicherzustellen, dass große und kleine Projekte zum Erfolg führen? Im antiken Griechenland konsultierten die Menschen Orakel, um die Zukunft zu erfahren. Sie waren ein fester Bestandteil ihrer Kultur und einige von ihnen, wie die Pythia von Delphi, sind auch heute noch sehr bekannt.

Heutzutage scheint die Menschheit mehr auf die Wissenschaft als auf übernatürliche Fähigkeiten zu vertrauen, und dank dieser Tatsache wird unsere Zeit von der Technologie umgestaltet. Zu diesen Technologien gehört die künstliche Intelligenz (KI), die derzeit eine Blütezeit erlebt und das große Interesse fast aller wissenschaftlichen Gemeinschaften und Wirtschaftszweige, einschließlich der Stromnetzbetreiber, auf sich zieht.

Denken Sie an Sprachassistenten, automatische Markierungen für Personen in sozialen Medien, Transkription von Sprachnachrichten, Erkennung von E-Mail-Spam und Wettervorhersagen - künstliche Intelligenz hat bereits tief in unser Leben eingegriffen. Inwieweit kann sich diese Technologie weiterentwickeln und bei Aufgaben eingesetzt werden, die ein hohes Maß an Verantwortung erfordern, wie z. B. die Übernahme von Schlüsselaufgaben beim Betrieb von Stromnetzen? Wie zuverlässig und robust kann ein KI-Algorithmus sein?

Trotz dieser Unwägbarkeiten ist die Begeisterung für die KI-Entwicklung ungebrochen. Mehrere renommierte Unternehmen und Institutionen wie IBM und das Massachusetts Institute of Technology (MIT) haben erkannt, dass wir uns derzeit auf dem Höhepunkt der überzogenen Erwartungen befinden und dass ein tieferes Verständnis der Relevanz dieser Technologie sowie ein verantwortungsvoller Umgang mit ihr für die Zukunft von größter Bedeutung sind.

In diesem Artikel versuchen wir, einige der Fragen rund um KI zu beantworten, indem wir einen Blick unter die Haube dieser Technologie werfen und dies anhand eines Anwendungsfalls illustrieren: Energieprognose auf der Grundlage von intelligenten Zählern und Wettervorhersage. Wir hoffen, dass dieser Artikel dazu beitragen kann, Ihr Verständnis für die Potenziale und Nachteile der künstlichen Intelligenz für Smart-Grids zu erweitern.

2 Smart-Grid-KI

2.1 Was ist Künstliche Intelligenz, Maschinelles Lernen und Deep-Learning?

Künstliche Intelligenz ist ein sehr aktives Forschungsgebiet mit praktischen Anwendungen, die Informatik und reale Datensätze kombinieren.

Künstliche Intelligenz zielt in der Regel darauf ab, Vorhersage- oder Klassifizierungsprobleme mit Hilfe von Ansätzen zu lösen, die auf fest kodiertem Wissen basieren, wobei Eingabe und Ausgabe mit Hilfe logischer Inferenzregeln programmiert werden, oder mit Systemen, die auf erworbenem Wissen basieren, das durch die Extraktion von Mustern aus Datensätzen gelernt wird. Der erste Ansatz wird als Wissensbasisansatz bezeichnet, während der zweite als maschinelles Lernen bekannt ist.

In diesem Artikel werden wir uns auf den Ansatz des maschinellen Lernens konzentrieren. Aber was ist maschinelles Lernen? Einfach ausgedrückt: Maschinen lernen, wie sie Wissen über die Welt aufnehmen können, indem sie Eingabe- und Ausgabedaten ohne vorherige Kenntnis ihrer Beziehungen zueinander korrelieren und sich stattdessen auf eine Reihe von Beispielen stützen. In den meisten Fällen kann die Anzahl der Beispiele sehr groß sein, je nach der Komplexität des Problems und der Art und Weise, wie die Eingabedaten, die oft als „Merkmale“ bezeichnet werden, die Ausgabe beschreiben können.

Ein Teilbereich des maschinellen Lernens ist das Deep-Learning, das sich entwickelt hat, um einige Einschränkungen des klassischen maschinellen Lernens zu überwinden. Deep-Learning kann Probleme lösen, die sich nur schwer in einer formalen Sprache formulieren lassen und die für den Menschen subjektiv und intuitiv erscheinen (z. B. Bild- und Spracherkennung). Die Lösung dieser Probleme erfordert Wissen über die reale Welt und in der Regel eine große Menge an robusten Daten.

Eine vereinfachte Darstellung der KI-Domäne mit den Bereichen maschinelles Lernen und Deep-Learning ist in Abbildung 1 zu sehen.




Abbildung 1 - Venn-Diagramm zur Definition des Bereichs der KI. Maschinelles Lernen und Deep-Learning sind Teilbereiche der KI. (Basierend auf Ian Fellow 2016 et al.)

Beim klassischen maschinellen Lernen basiert das System auf mathematischen Algorithmen, die häufig aus dem Bereich der Statistik stammen, wie lineare Regression, logistische Regression, naive Bayes, Random Forest, Gradient Boosted, Bäume, usw.

Das klassische maschinelle Lernen erfordert keine hohe Rechenleistung und seine Ergebnisse sind relativ einfach zu interpretieren. Der Nachteil ist jedoch, dass es einen erheblichen Aufwand für die richtige Aufbereitung der Daten - das Feature Engineering - erfordert und die Algorithmen Schwierigkeiten haben können, große Datensätze oder komplexe Funktionen zu lernen.

Deep-Learning kann die Nachteile des klassischen maschinellen Lernens überwinden, indem es neuronale Netze verwendet, die komplexe Funktionen und große Datensätze besser handhaben können, allerdings um den Preis höherer Rechenkosten und der Verwendung empirischerer Strategien, die eine Erklärung der Ergebnisse erschweren.

Das einfachste tief lernende neuronale Netz ist das Feedforward-Netz. Eine Darstellung des Feedforward-Netzes ist in Abbildung 2 zu sehen. Feedforward-Netze bestehen im Allgemeinen aus (i) einer Eingabeschicht, (ii) einer oder mehreren verborgenen Schichten und (iii) einer Ausgabeschicht. Die Aufgabe der versteckten Schichten besteht darin, komplexere Funktionen besser zu approximieren. Theoretisch kann eine einzige verborgene Schicht mit genügend Knoten jede Funktion approximieren, aber der Rechenaufwand und die Komplexität des Problems können so hoch sein, dass der Algorithmus in der Praxis keine Lösung findet. Aus diesem Grund können mehrere versteckte Schichten verwendet werden, um eine einzelne komplexe Rechenaufgabe in mehrere einfachere Rechenaufgaben aufzuteilen. Die Anzahl der versteckten Schichten wird häufig auch verwendet, um den Grad der Tiefe eines neuronalen Netzes zu beschreiben.

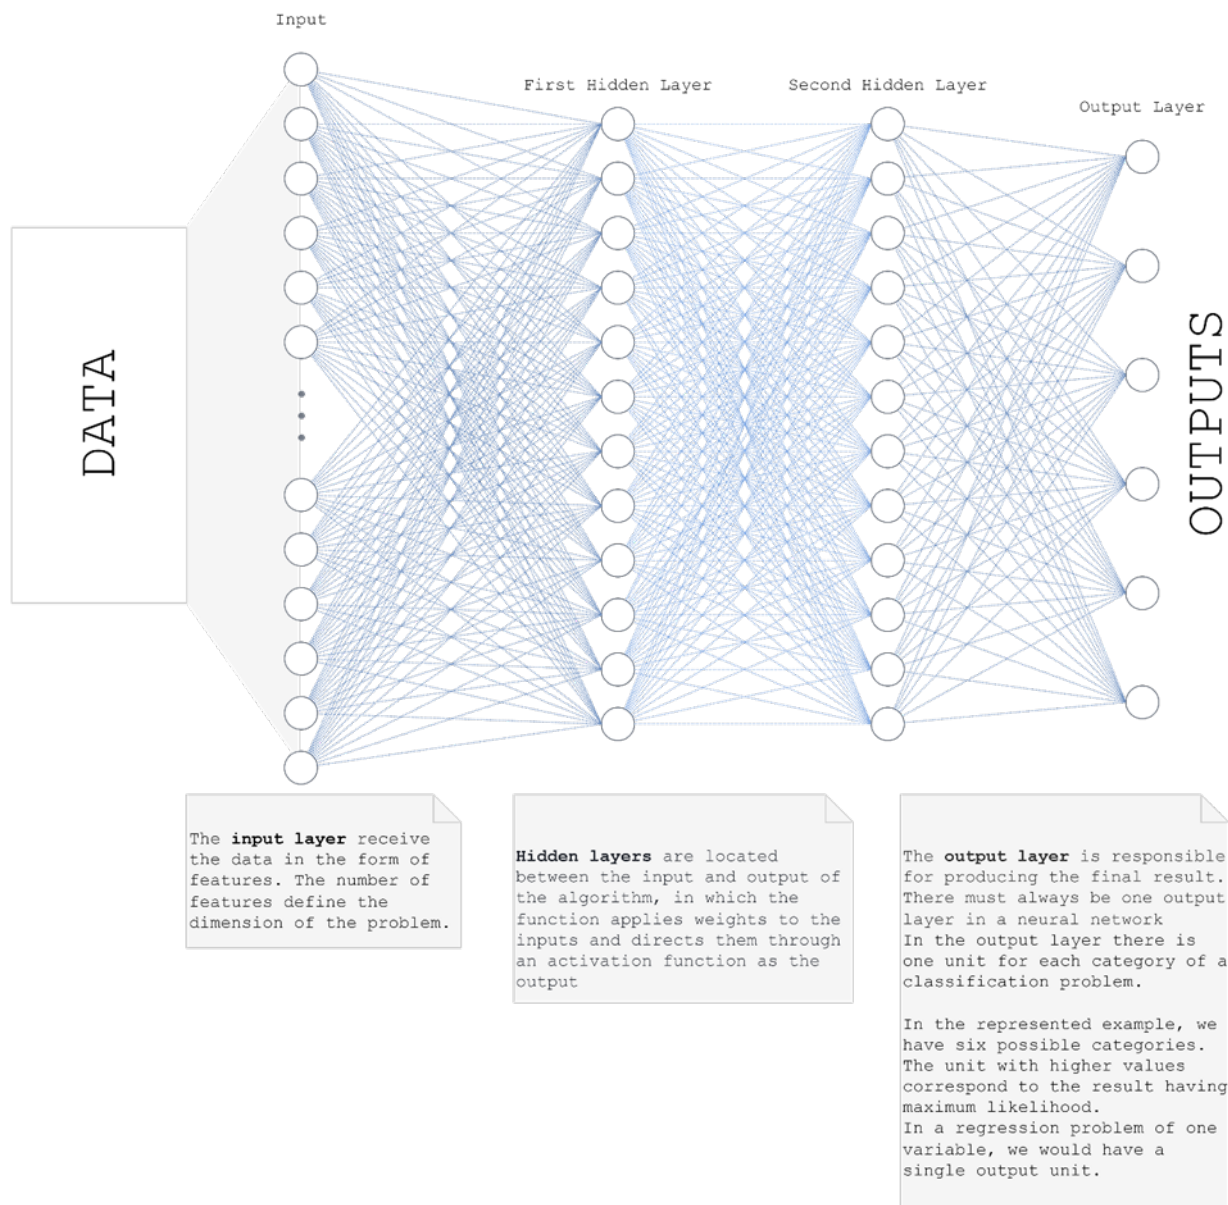


Abbildung 2 - Beispiel eines neuronalen Feedforward-Netzes mit zwei versteckten Schichten

Neben den neuronalen Feedforward-Netzen sind weitere bekannte und häufig verwendete neuronale Netze das Convolutional-Neural-Network CNN, rekurrente neuronale Netze RNN (die manchmal in Kombination verwendet werden) und Autoencoder. Diese wurden entwickelt, um spezifische Probleme wie Bild- und Texterkennung, Verarbeitung natürlicher Sprache und Zeitreihenvorhersagen besser zu lösen. Sie sind die Grundlage des Deep-Learning. In der Praxis umfasst es viel mehr, und die Forscher erforschen ständig neue Modelle und Lösungen.

Jetzt wissen wir ein wenig mehr über maschinelles Lernen, aber wie funktioniert es und wie können wir es für Smart-Grid-Anwendungen nutzen?

2.2 Wie Machine-Learning funktioniert

Wir können uns das maschinelle Lernen als einen iterativen Prozess der Schätzung, Bewertung und Optimierung vorstellen, der so lange wiederholt wird, bis die gewünschte Genauigkeit des Modells erreicht ist. Dies wird als Modelltraining bezeichnet. Ein Modell muss auch einen Prozess der Validierung und des Testens durchlaufen, um zu prüfen, ob das Modell auch bei zuvor nicht gesehenen Datensätzen (Testdaten) gut funktioniert.

Es ist zu beobachten, dass ein Modell, das sich zu eng an ein Trainingsdatensatz anpasst, bei den Testdaten möglicherweise keine gute Leistung erbringt. Dies wird als Overfitting bezeichnet und ist beim maschinellen Lernen nachteilig. Es gibt zahlreiche Regularisierungstechniken zur Vermeidung von Overfitting, aber im Prinzip zielen alle mit unterschiedlichen Ansätzen darauf ab, die Leistung des Modells bei Trainings- und Testbeispielen auszugleichen. Dieser Prozess wird auch als Generalisierung bezeichnet.

Aufgrund der Unterschiede zwischen Trainings- und Testdaten ist es jedoch unmöglich, ein Modell vollständig zu verallgemeinern und unsere Vorhersagen 100 % genau zu machen, selbst wenn das Modell mit sehr großen Datensätzen trainiert wurde. Das bedeutet, dass selbst sehr gut funktionierende Modelle fehlerhafte Ergebnisse liefern können. Ein tiefgreifendes Verständnis des Modellverhaltens und der möglichen Fehler in den Ergebnissen sowie die Auswirkungen auf reale Anwendungen müssen verantwortungsbewusst bedacht werden. Immer dann, wenn ein solcher Fehler schwerwiegende Folgen haben kann, sei es in Bezug auf die Sicherheit von Menschen oder die Schädigung von Eigentum oder Ökosystemen, müssen maschinelle Lernverfahren den Menschen in die Schleife einbeziehen.

Wenn es verantwortungsvoll eingesetzt wird, kann maschinelles Lernen sehr nützlich sein und die Abläufe in verschiedenen Sektoren erheblich verbessern. Sage Journals berichtet, dass KI bis 2025 57 % der heutigen traditionellen Arbeitsplätze automatisieren wird, wobei das Datenvolumen um 530 % zunimmt. Können wir uns eine ähnliche Auswirkung auf intelligente Stromnetze vorstellen?

Werfen wir einen Blick auf das reale KI-Anwendungsszenario für Smart-Grids, das die aktuellen und vielversprechendsten Anwendungsfälle umfasst.

2.3 Anwendung von maschinellem Lernen im Smart-Grid

„Der Klimawandel ist nicht auf Eis gelegt“. Dies ist die Aussage der Vereinten Nationen, nachdem sie festgestellt haben, dass das Jahr 2019 das zweitwärmste Jahr am Ende des wärmsten jemals aufgezeichneten Jahrzehnts (2010-2019) war.

Experten sind der Ansicht, dass der Rückgang der Kohlendioxidemissionen, der durch die Reiseverbote und die Konjunkturabschwächung der letzten beiden Jahre (2020-2021) verursacht wurde, keinen wesentlichen Einfluss auf den langfristigen Klimawandel hat.

Bei den Programmen zur Dekarbonisierung des Energiesektors spielen erneuerbare Energien eine Schlüsselrolle, und die Stromversorger arbeiten an neuen Strategien, um die gemeinsame Nutzung erneuerbarer Energien voranzutreiben und dabei die Verteilerebene des Stromnetzes noch stärker einzubeziehen.

Vor diesem Hintergrund müssen intelligente Technologien zum Einsatz kommen, die das Stromnetz in die Lage versetzen, die erwartete Zunahme von Elektrofahrzeugen, den weiteren Anstieg der Stromerzeugung aus erneuerbaren Energien und neue Energiespeichertechnologien zu bewältigen.

Das maschinelle Lernen hat sich bereits in mehreren Anwendungen als guter Verbündeter von Smart-Grid-Technologien erwiesen, und die laufende Forschung zeigt interessante Anwendungsbereiche auf, die weiterentwickelt werden müssen.

Um gut zu funktionieren, braucht maschinelles Lernen gute Merkmale, d. h. ausreichend große Datensätze, die die Beobachtungen beschreiben können. Intelligente Netztechnologien können solche großen und genauen Daten liefern. Aus der Sicht der Betreiber von Stromnetzen müssen maschinelle Lernlösungen jedoch auch robust, widerstandsfähig und zuverlässig sein und schließlich genauso gut funktionieren wie Menschen. Diese Aussage ist komplexer als sie scheint, denn die Bewertung der Leistung kann sehr schwierig sein. Nehmen wir ein Modell, das fast alle Vorhersagen richtig trifft. Es würde eine sehr hohe Genauigkeit erzielen, aber wenn dieses Modell hypothetisch zur Automatisierung einer sehr kritischen Aufgabe eingesetzt wird, könnten die wenigen falschen Vorhersagen das gesamte System gefährden. Im Gegensatz dazu könnte ein Mensch weniger genau sein als der Algorithmus, aber er kann unerwartete Situationen oder Zweifel klüger lösen, indem er zum Beispiel weitere Untersuchungen durchführt oder andere Experten konsultiert. Natürlich gibt es auch Tätigkeiten, die Maschinen objektiv besser ausführen als Menschen. Zum Beispiel die Erkennung von Anlagenfehlern auf der Grundlage kontinuierlicher Messdatenströme mit einer Abtastung von etwa einer Sekunde. Dies wäre für den Menschen sehr kompliziert oder unmöglich, für eine Maschine jedoch recht einfach.

Maschinelles Lernen ist ein gutes Werkzeug zur Unterstützung intelligenter Netze bei Wartung, Systembetrieb und Vorhersage, z. B. bei der frühzeitigen Erkennung von Systemausfällen, der Erkennung von Inselösungen, der Unterstützung bei der Neusynchronisierung des Systems, dem Lastabwurfmanagement, der Optimierung des Erzeugungs-Last-Managements, der Vorhersage der Strom- und Energieerzeugung aus erneuerbaren Energien, der Erkennung von Lademustern für Elektrofahrzeuge, der Energiepreisvorhersage usw.

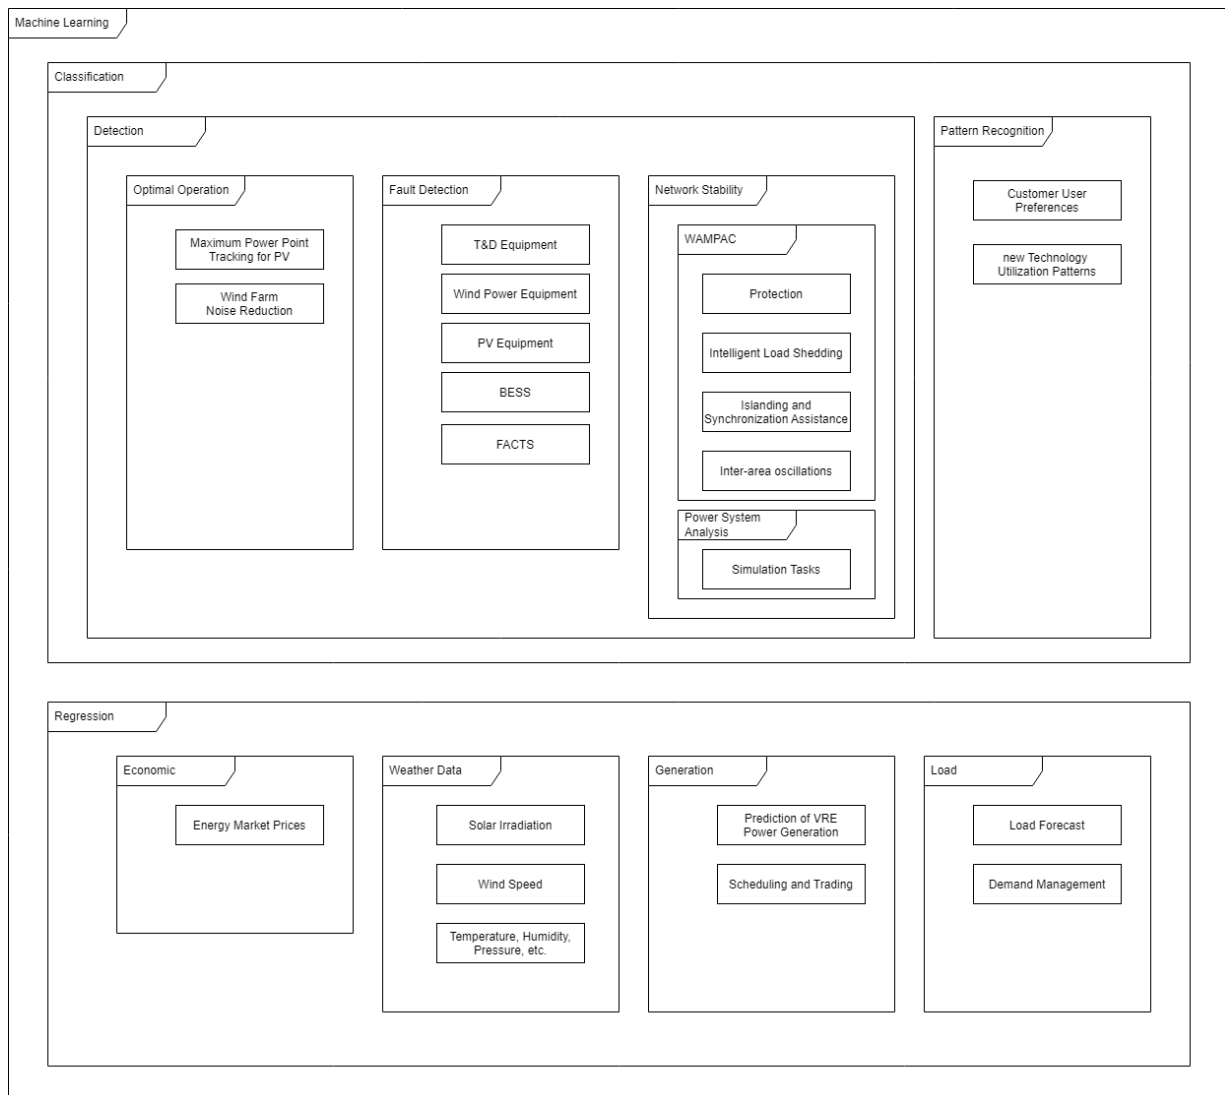


Abbildung 3 - Überblick über Anwendungen des maschinellen Lernens für intelligente Stromnetze. Die Ergebnisse sind nicht erschöpfend, sondern eine komprimierte Zusammenfassung von etwa 250 Forschungsarbeiten, die in der IEEE-Datenbank verfügbar sind.

Das Grundkonzept besteht darin, dass maschinelles Lernen gut für Klassifizierungs- und Prognoseprobleme geeignet ist. Ausgehend von diesen beiden Makrobereichen können andere Unterbereiche gefunden und detailliert werden. In Abbildung 3 wird eine Zusammenfassung der vorteilhaftesten Anwendungsfälle des maschinellen Lernens für Smart-Grid-Anwendungen dargestellt, wobei die entsprechenden Bereiche und Unterbereiche angegeben werden.

2.4 Risiken und Herausforderungen von KI-Anwendungen in intelligenten Netzen

Das grundlegende Ziel von Smart-Grids ist die Optimierung der Energieeffizienz und die Bewältigung komplexer Szenarien, die mit klassischen T&D-Technologien nicht zu bewältigen sind. Dieser Weg ist nicht frei von Risiken. Cyberangriffe, Softwarefehler und unvorhersehbare

Szenarien müssen bei der Konzeption und Planung von intelligenten Netzen sorgfältig berücksichtigt werden, insbesondere in Kombination mit maschinellem Lernen. Starke Netze und Kommunikationsinfrastrukturen sind eine Voraussetzung für die Umsetzung dieser neuen Technologien. Weitere Herausforderungen sind die Datensicherheit, die Skalierbarkeit der Daten und die Latenzzeit. Latenz ist hier definiert als die Lücke zwischen der Datenerzeugungszeit und der Datenverfügbarkeitszeit für Anwendungen.

Die Entwicklung neuer Technologien, das exponentielle Wachstum der Rechenleistung von Computern und die für die Analyse großer Datenmengen geeignete Infrastruktur helfen bei der Bewältigung dieser Herausforderungen.

Aber wie sehr kann maschinelles Lernen den Netzbetrieb unterstützen? Versuchen wir, diese Frage zu beantworten, indem wir einen realen Anwendungsfall für die Energieprognose genauer unter die Lupe nehmen.

Warum die Energieprognose als Anwendungsfall? Weil die Energieprognose bereits ein wichtiges Verfahren für den Betrieb des Systems ist und in Zukunft aufgrund des zunehmenden Einsatzes von Ladestationen für Elektrofahrzeuge und der Erzeugung erneuerbarer Energien auf der Verteilungsebene noch wichtiger werden wird. In diesem Zusammenhang werden die verfügbaren Daten aus den Energieanlagen, intelligenten Zählern und Wetterstationen von entscheidender Bedeutung sein.

2.5 Mit maschinellem Lernen unterstützte Energieprognosen auf der Grundlage von intelligenten Zählern und Wettervorhersagen - der Fall London, UK

Vor etwa zehn Jahren wollte die britische Regierung, dass die Energieversorger in jedem Haushalt in England, Wales und Schottland intelligente Zähler installieren. Es gab mehr als 26 Millionen Haushalte, mit dem Ziel, dass bis zum letzten Jahr (2020) jeder Haushalt einen intelligenten Zähler hat.

Der Datensatz, den wir für diese Analyse verwendet haben, ist eine überarbeitete Version der Daten des Londoner Datenspeichers, der die Energieverbrauchswerte von etwa zwei Jahren für eine Stichprobe von 5.567 Londoner Haushalten enthält, die an dem von UK Power Networks geleiteten Projekt Low-Carbon London teilgenommen haben.

Klassische Machine-Learning- und Deep-Learning-Modelle wurden definiert, trainiert und bewertet, um ihre Leistung bei der Vorhersage des täglichen Energieverbrauchs zu vergleichen und ihre Ergebnisse mit einer naiven Vorhersage zu vergleichen, die einfach davon ausgeht, dass die an einem bestimmten Tag verbrauchte Energie gleich der am Vortag verbrauchten Energie ist.

Ziel unserer Studie war es auch, das beste Modell zu ermitteln, das eine Energieprognose mit einem mittleren absoluten Fehler von weniger als 2 % liefert.

Es wurden die klassischen Algorithmen des maschinellen Lernens wie lineare Regression, Gradient-Boosted-Trees und Random-Forest analysiert. Außerdem wurde ein rekurrentes

neuronales Netz für tiefes Lernen namens Long-Term-Short-Memory (LSTM) implementiert, das sich sehr gut für Zeitreihenvorhersagen eignet.

Die Architektur eines rekurrenten neuronalen LSTM-Netzes unterscheidet sich deutlich von der eines neuronalen Feedforward-Netzes. Eine LSTM-Einheit besteht aus einer Zelle, die Informationen über Zeitintervalle hinweg überträgt, und aus Gattern (Input-Gate, Output-Gate und Forget-Gate), die den Informationsfluss zwischen aufeinanderfolgenden Einheiten regeln. Mit dieser Architektur, die mit der einfacheren Form des neuronalen Feedforward-Netzes nicht vergleichbar ist, kann das LSTM ganze Datenreihen verarbeiten und so die Genauigkeit der Vorhersagen verbessern.

Von den getesteten Algorithmen schnitt das LSTM-Modell für tiefes Lernen am besten ab (bei Testdaten), wie aus den Ergebnissen in Abbildung 4 ersichtlich ist.




Abbildung 4 - Vergleich der Leistung (R2) von Modellen des maschinellen Lernens bei Energieprognosen

Ein Vergleich der Vorhersage der Energie im Vergleich zu den wahren Daten für die GBT- und LSTM-Modelle ist in Abbildung 5 und Abbildung 6 dargestellt.




Abbildung 5 - Vorhersage im Vergleich zum wahren Wert - GBT-Modell (Testdaten)




Abbildung 6 - Vorhersage im Vergleich zum wahren Wert - LSTM-Modell (Testdaten)

Wie in den obigen Diagrammen zu sehen ist, zeigt das LSTM-Modell die beste Leistung.

Um wie viel ist das LSTM besser als die naive Vorhersage, bei der angenommen wird, dass der Energieverbrauch an einem bestimmten Tag gleich dem Energieverbrauch am Vortag ist?

Die Antwort zeigt das Diagramm in Abbildung 7.

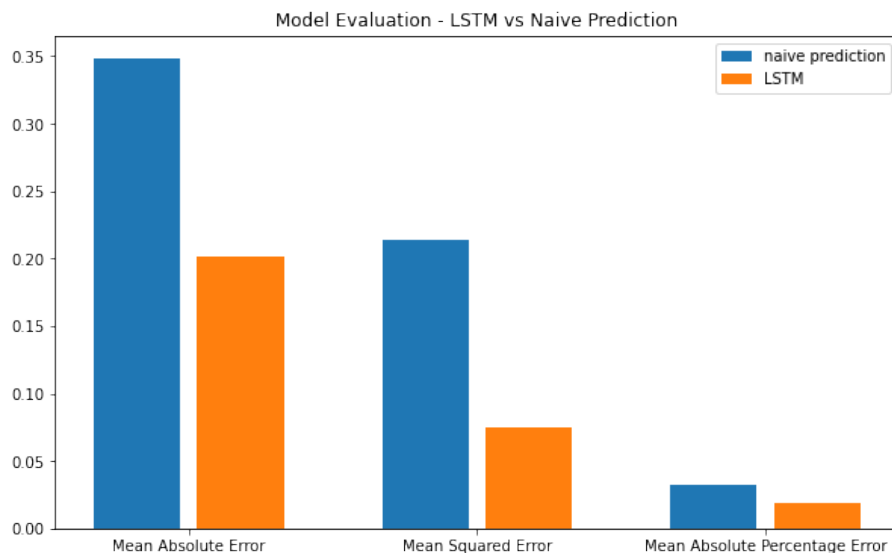


Abbildung 7 - Leistung des LSTM-Modells im Vergleich zur naiven Vorhersage. Im Vergleich zur naiven Vorhersage, bei der davon ausgegangen wird, dass der Energieverbrauch eines bestimmten Tages gleich dem des Vortages ist, bietet das LSTM-Modell eine deutliche Verbesserung.

Das LSTM übertrifft eine naive Vorhersage in allen berechneten Leistungsindizes bei weitem. Im Falle des mittleren quadratischen Fehlers ist die Verbesserung von etwa 0,213 auf 0,075 recht beeindruckend. Dies bedeutet, dass LSTM große Fehler, die durch die quadratische Operation des Indexes bestraft werden, recht gut begrenzt. Der mittlere absolute Fehler in Prozent ist ebenfalls deutlich gesunken, und zwar von etwa 3,3 % auf 1,9 %.

In diesem Anwendungsfall haben wir ganz erstaunliche Verbesserungen bei den Prognosen durch den Einsatz von Deep-Learning-Algorithmen festgestellt, auch ohne eine vollständige Optimierung des Modells. Das Risiko einer Überanpassung wurde durch einige grundlegende Einstellungen der Hyperparameter, wie Lernrate, Stapelgröße und Anzahl der Epochen, recht gut gemildert.

In einem Strommarkt mit einem hohen Anteil an erneuerbaren Energien, Elektrofahrzeugen und Speichersystemen wäre der Unterschied zwischen naiver Vorhersage und Deep-Learning-Modell wahrscheinlich noch größer.

Weitere Informationen über die Studie finden Sie in einem [eigenen Artikel von ENGIE Impact](#).

2.6 Schlussfolgerungen

Die Kombination von KI, insbesondere von maschinellem Lernen und Deep-Learning, mit Smart-Grid-Anwendungen wird einen grundlegenden Beitrag zur Verbesserung des Betriebs elektrischer Systeme leisten, die in Bezug auf Architektur und Komplexität einem grundlegenden Wandel unterworfen sind. KI wird bereits in großem Umfang in Smart-Grid-Systemen eingesetzt, aber es wird erwartet, dass ihre Präsenz weiter zunimmt, und es werden weitere Innovationen in beiden Technologien erwartet.

In diesem Artikel haben wir einen erfolgreichen Anwendungsfall von KI für Energieprognosen vorgestellt, ein Thema, das unserer Meinung nach von wachsendem Interesse ist.

Schließlich erfordert der erfolgreiche Einsatz des maschinellen Lernens für intelligente Netze robuste, sichere und skalierbare Daten und eine hohe Rechenleistung.

Mit der weit verbreiteten Einführung neuer Kommunikationstechnologien (z. B. 5G), dem Internet der Dinge (IoT) und visionären Download-Geschwindigkeiten von bis zu 10 Gb/s wird die Menge der verfügbaren Daten voraussichtlich rasch zunehmen. Auch bei der Rechenleistung wird ein schnelles Wachstum erwartet. Dies wird auch eine robuste, sichere und skalierbare digitale Infrastruktur erfordern, die verteilte Rechenzentren miteinander verbindet.

Gleichzeitig werden diese Infrastrukturen mehr Strom aus dem Netz benötigen, was sich negativ auf den Klimawandel auswirken kann. Daher sollten erhebliche Anstrengungen unternommen werden, um die Algorithmen und bewährten Verfahren des maschinellen Lernens weiter zu verbessern, um die Rechenkosten zu optimieren und das maschinelle Lernen zu einer nachhaltigen Lösung für die Zukunft zu machen.

Über den Autor:



Dr. Luca Pizzimbone ist ein Schlüsselexperte für die Analyse von Energiesystemen, der sich mit der Energiewende und der Entwicklung von Stromübertragungs- und -verteilungsnetzen weltweit beschäftigt. Er besitzt ein Diplom in Elektrotechnik vom C.I.T.I. G. Galilei in Genua (Italien), einen Dokortitel (Laurea di Dottore) in Elektrotechnik von der Universität Genua und ist ein von IBM zertifizierter Advanced Data Scientist.

Als Teil der Abteilung Energieübertragung und -verteilung der Tractebel Engineering GmbH hat er Projekte in den Bereichen Netzplanung, erneuerbare Energien, Hybridsysteme und intelligente Netze in Afrika, Asien, Europa und dem Nahen Osten geleitet.

Er ist in Bad Vilbel, Deutschland, ansässig.