

Anlageneinsatzplanung

Innovative Lastprognosen mit »Deep Learning«-Methoden

Für Fernwärmeversorger spielt die Lastprognose bei der Anlageneinsatzplanung eine zentrale Rolle. Benötigte Fernwärme oder auch -kälte lassen sich umso kostengünstiger, effizienter und emissionsärmer bereitstellen, je exakter die zu erwartende Last abgeschätzt werden kann. Ein neuartiges, an der Hochschule Kempten entwickeltes Verfahren namens »Deep DHC« kann die Genauigkeit dieser Lastprognosen deutlich erhöhen.

Fernwärmenetze erreichen Gesamtlängen von mehreren 100 Kilometern. Dies ist eine erhebliche Herausforderung für die optimale Versorgung der Leitungsnetze. Vor allem durch den zunehmenden Einsatz von thermischen Speichern innerhalb der Wärmenetze bieten sich Anlagenbetreibern vielfältige Optimierungsmöglichkeiten für den Anlagenbetrieb. So kann mit einem Wärmespeicher beispielsweise der Einsatz von fossil befeuerten und kostenintensiven Spitzenlastkesseln vermieden werden. Voraussetzung für den optimierten Betrieb ist jedoch eine möglichst genaue Kenntnis des Zeitpunkts und der Höhe der zu erwartenden Lastspitzen im Netz. Hier setzt das innovative Lastprognoseverfahren »Deep DHC« (Deep Learning for District Heating and Cooling) an, das im vom Bundesministerium für Wirtschaft und Energie geförderten Forschungsprojekt »KWK-Flex« entwickelt wurde. Das Verfahren wird zusammen mit den Projektpartnern Fernwärme Ulm GmbH und ZAK Energie GmbH an deren Fernwärmeversorgungsanlagen validiert und optimiert.

Betrachtetes Fernwärmenetz und Datenbasis

Das zur Entwicklung des Lastprognoseverfahrens untersuchte Teilnetz der Fernwärme Ulm hat eine Gesamtlänge von 40 km. Es deckt den jährlichen Wärmebedarf von 1 100 Haushalten in Höhe von durchschnittlich 75 GWh. Für das Lastprognoseverfahren wurden Messdaten der letzten 15 Jahre in einer stündlichen Auflösung eingesetzt, die in Summe insgesamt 131 400 Datenreihen bilden. Jeder stündliche Daten-

Parameter	Korrelationskoeffizient
vorangegangene Last	0,984
Vortagslast	0,957
gemittelte Last der letzten 24 h	0,952
Luftfeuchtigkeit	0,374
Saisonwert	0,369
Windgeschwindigkeit	0,130
Feiertag	0,105
Stunde	0,087
Samstag	- 0,002
Tag	- 0,003
Sonntag	- 0,004
Wochentag	- 0,005
Windrichtung	- 0,014
Luftdruck	- 0,021
Jahr	- 0,027
Werktag	- 0,037
Monat	- 0,194
gemittelte Lufttemperatur der letzten 24 h	- 0,787
Taupunkt	- 0,854
Lufttemperatur	- 0,864

Tafel 1. Daten nach Korrelationskoeffizient geordnet

satz bestand aus 20 Parametern, d. h. Messdaten aus dem Fernwärmenetz oder Wetterinformationen wie Lufttemperatur, Windrichtung oder Windgeschwindigkeit. Der Zusammenhang einzelner Parameter und der dazugehörigen Fernwärmelast wurde anhand einer Korrelationsanalyse überprüft (Tafel 1).

Es zeigt sich, dass die Merkmale Monat (Korrelationskoeffizient - 0,19) und Windgeschwindigkeit (0,13) nur eine geringe Auswirkung auf die zu erwartende Last haben. Mittlere Effekte weisen sowohl die Luftfeuchtigkeit (0,37) als auch der Saisonwert (0,36) auf. Am stärksten mit der Fernwärmelast korrelieren die Merkmale Temperatur (- 0,86), Taupunkt (- 0,85) sowie jedes Merkmal, das in Zusammenhang mit der vor-



M. Eng. **Till Faber**, und M. Sc. **Johannes Groß**, wissenschaftliche Mitarbeiter, Prof. Dr.-Ing. **Matthias Finkenrath**, Projektleiter, Institut für Energie- und Antriebstechnik, Hochschule Kempten, Kempten



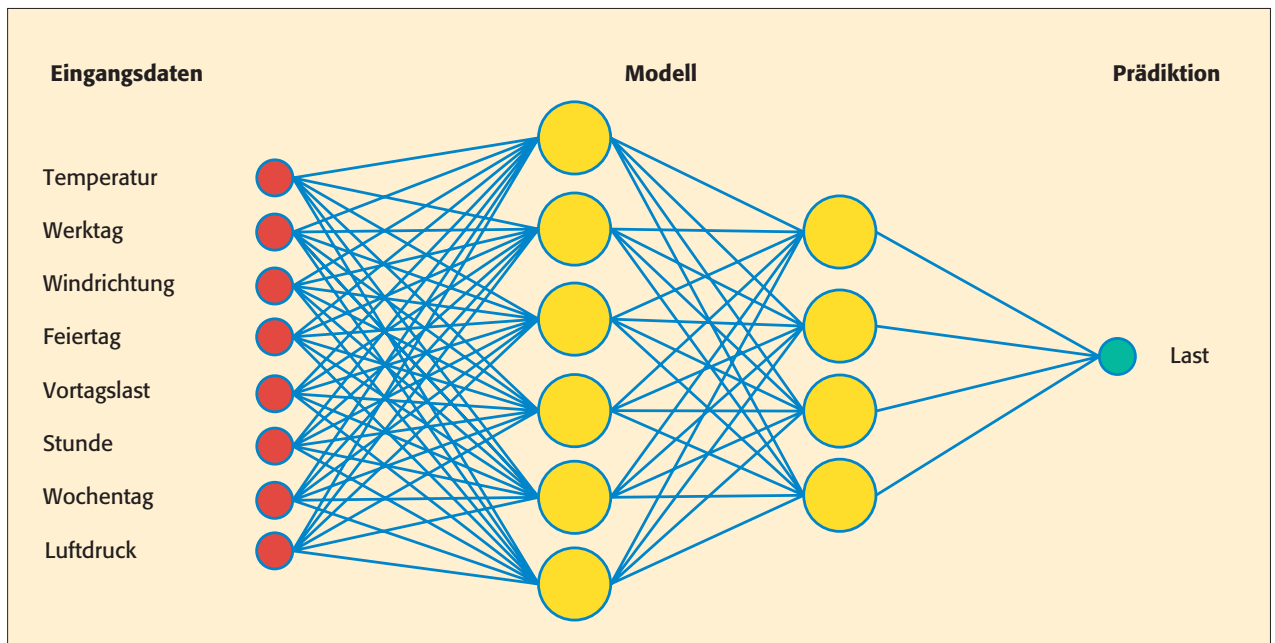


Bild 1. Beispielhafter Aufbau eines künstlichen neuronalen Netzes zur Lastprognose

herigen Last steht. Die geschilderte vorangehende Untersuchung der Datenbasis ist für die Lastprognose von zentraler Bedeutung. So kann etwa der Einfluss des Werktags für das betrachtete Wärmenetz bei der Prognose vernachlässigt werden, da dieser nur sehr schwach mit der zu erwartenden Last korreliert ($-0,037$). Für Netze mit einem sehr hohen Industrieanteil ist dagegen für diesen Parameter eine weitaus größere Bedeutung zu erwarten.

Kurzüberblick Prognoseverfahren

Die in den letzten Jahrzehnten untersuchten Ansätze zur Lastprognose beruhen zumeist auf maschinellen Lernverfahren wie neuronalen Netzen oder klassischen Ansätzen wie Entscheidungsbaumen [1;2].

Künstliche neuronale Netze werden seit Anfang der 1990er-Jahre für die Lastprognose eingesetzt. Hierfür wird ein neuronales Netz mit zurückliegenden Messdaten trainiert, so dass das trainierte Modell anhand der Eingangsgrößen die abhängige Ausgangsgröße innerhalb einer gewissen Genauigkeit bestimmen kann. Bild 1 zeigt den schematischen Aufbau eines neuronalen Netzes zur Lastprognose eines Fernwärmenetzes.

Ein Entscheidungsbaum ist eine hierarchische Datenstruktur. Der Algorithmus bricht den Eingaberaum

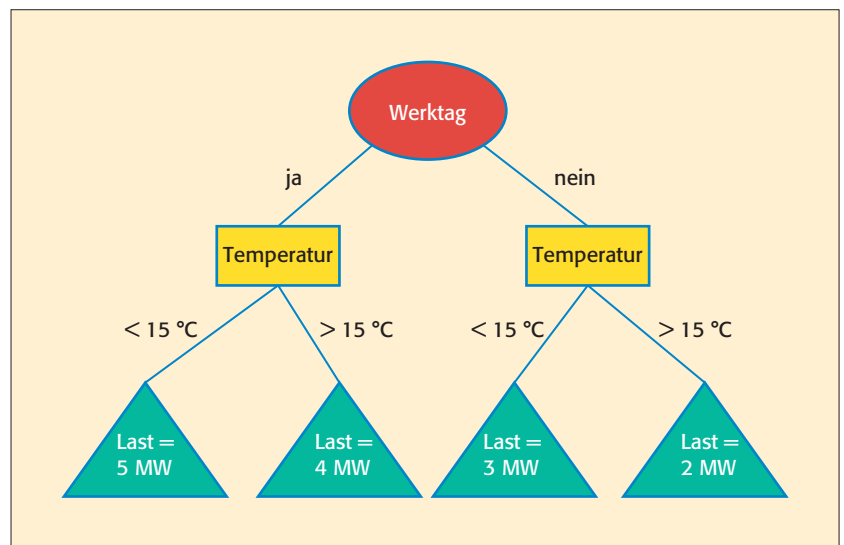


Bild 2. Beispielhafter Aufbau eines Entscheidungsbaums zur Lastprognose

mit einem Distanzmaß (z. B. Euklidische Norm) in mehrere Regionen mit jeweils separaten Parametern auf [3].

Jeder Knoten enthält hierbei die Informationen über das verwendete Merkmal mit dem dazugehörigen Wertekriterium des Zielintervalls. Bild 2 zeigt den vereinfachten Aufbau eines Entscheidungsbaums für die Bestimmung der Fernwärmelast. Im ersten Schritt wird differenziert zwischen Werktag oder Wochenende. Der zweite Schritt grenzt den Temperaturbereich ein, woraus sich als Ergebnis die zu erwartende Last ergibt.

Deep DHC

In den meisten Fällen ist die Prognosegüte neuronaler Netze höher als die von Entscheidungsbaumen. Gegenüber Entscheidungsbaumen weisen neuronale Netze jedoch Schwächen bei der Extrapolation außerhalb bekannter Wertebereiche auf. Das an der Hochschule Kempten entwickelte Verfahren »Deep DHC« kombiniert die beiden vorgestellten Ansätze, um die Stärken beider Verfahren zu vereinen. So verwendet das hier vorgestellte »Deep DHC«-Verfahren einerseits konven-

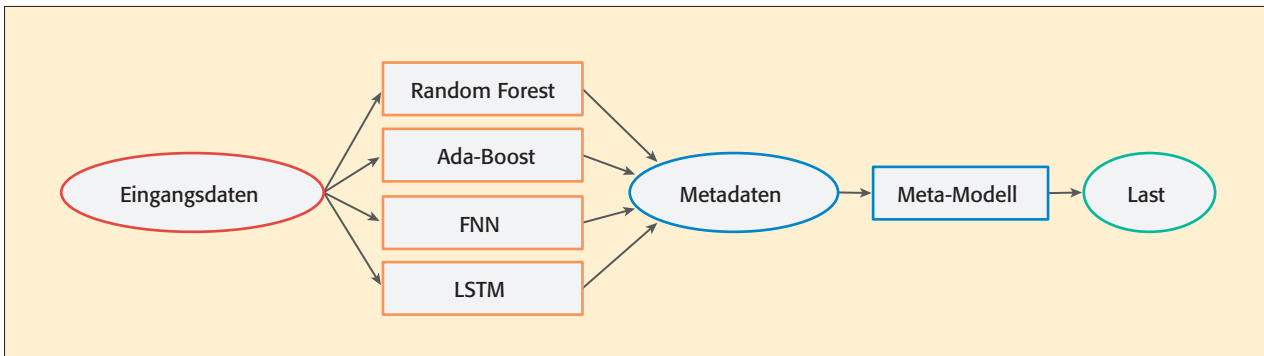


Bild 3. Aufbau »Deep DHC«-Verfahren

tionelle maschinelle Lernverfahren vom Typ Entscheidungsbäume wie die Verfahren »Ada-Boost« und »Random Forest« [4]. Zusätzlich kommen künstliche neuronale Netze zum Einsatz. Neben einfachen neuronalen Feed-Forward-Netzen (FNN) wird erstmalig auch eine neuartige »Deep Learning«-Netzstruktur bestehend aus Long-Short-Term-Memory-(LSTM-)Zellen verwendet. Das LSTM-Verfahren hat sich bereits in der modernen Spracherkennung überaus bewährt [5]. Um bestmögliche Lastvorhersagen zu erreichen, werden die genannten Ausgangsverfahren zur Lastprognose durch ein weiteres maschinelles Lernverfahren kombiniert und gewichtet. Diese Vorgehensweise wird in Bild 3 veranschaulicht. In Bild 3 ist mit »Meta-Modell« das maschinelle Lernverfahren gemeint, das durch Training die bestmögliche Kombination zuvor ausgeführter Lastprognosen der Einzelverfahren ermittelt.

Ergebnisse

Ergebnisse eines Vergleichstests der verschiedenen Lastprognoseverfahren mit Messdaten aus dem Betrieb des zu Beginn beschriebenen Teilnetzes der Fernwärme Ulm sind in Bild 4 dargestellt. Für den Test wurde mit allen beschriebenen Verfahren eine Lastprognose über 72 h durchgeführt. Die dazu verwendeten Eingangsdatensätze aus dem Anlagenbetrieb waren zuvor weder zum Training noch zur Validierung der Einzelverfahren verwendet worden. Für die Wetterdaten wurden archivierte Wetterprognosen herangezogen, so dass die Lastprognose-Randbedingungen bei dem Test identisch mit denen eines realen Kraftwerksbetriebs waren. Die Lastprognosen

wurden für alle Verfahren mit dem Erwartungswert verglichen. Es zeigt sich deutlich, dass alle Verfahren mit einer mittleren absoluten Abweichung (mean absolute percentage error; MAPE) von < 6 % eine vergleichbar hohe Genauigkeit aufweisen.

Das zuvor beschriebene »Deep DHC«-Verfahren steigert die mittlere Genauigkeit um fast 1 Prozentpunkt (3,51 %) gegenüber dem besten Einzelverfahren LSTM (4,48 %). Für den Praxiseinsatz in Fernwärmenetzen und die Anlageneinsatzoptimierung besonders bedeutend ist zudem die mit dem neuen Verfahren mögliche Senkung der maximalen Abweichung der Lastprognose. So variiert die maximale Abweichung der Einzelverfahren von 15 % (LSTM) bis hin zu > 20 % (Ada-Boost). Beim »Deep DHC«-Verfahren liegt dagegen die maximale Abweichung im Vergleich zu den tatsächlich gemessenen Lastdaten bei < 10 %.

Bild 5 zeigt den direkten Vergleich der Prognose des »Deep DHC«-Verfahrens und der tatsächlich eintretenden Last. Es ist zu erkennen, dass die Lastspitzen sowie der grundsätzliche Verlauf sehr gut von dem Verfahren vorhergesagt werden können. Lediglich in Stunde 32 der Vorhersage kommt es zu der auch in Bild 4 aufgeführten maximalen Abweichung von 9,13 %. Mit 11,35 MW liegt die prognostizierte Fernwärme-last um 0,95 MW über der tatsächlichen Last von 10,4 MW.

Fazit und Ausblick

In der vorliegenden Arbeit wurden unterschiedliche Verfahren untersucht, die zur Prognose der Last in Fernwärme- oder -kältenetzen im Rahmen einer Anlageneinsatzplanungsoptimierung eingesetzt werden können. Zudem wurde das neu entwickelte Lastprognoseverfahren

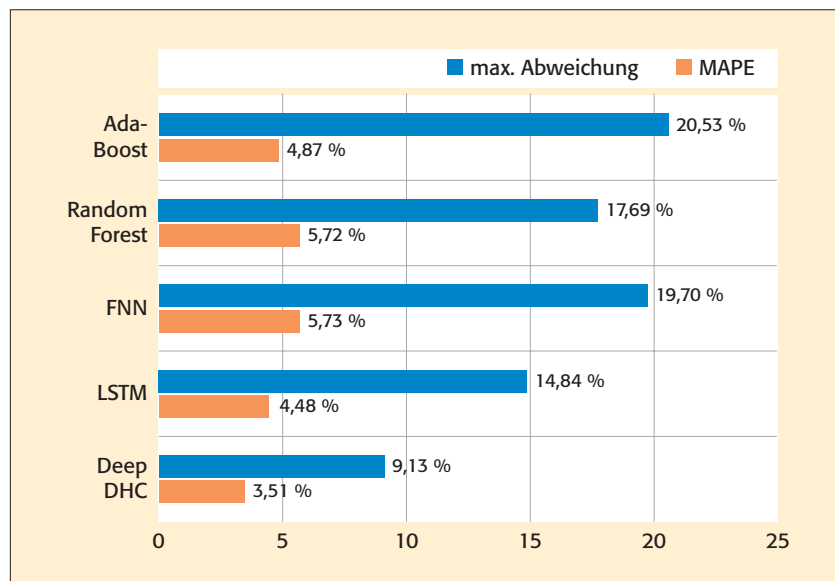


Bild 4. Ergebnisse des Vergleichstests zur Lastprognose




Bild 5. Vergleich von Prognoseverlauf und gemessener Last

»Deep DHC« vorgestellt. Dieses ermöglicht, durch gezieltes Kombinieren einzelner Prognoseverfahren eine deutliche Verbesserung der Prognosegüte für Fernwärmelasten zu erzielen. Vergleiche mit gemessenen Lastdaten aus einem Teilnetz der Fernwärme Ulm ergeben sehr geringe mittlere und absolute Abweichungen im Bereich weniger Prozent. Im weiteren Projektverlauf wird das Verfahren weiter optimiert. Zusätzlich wird das entwickelte Verfahren zurzeit in Form eines vollautomatischen Lastprognose-Tools in den Leitstand des Projektpartners Fernwärme Ulm integriert, um so stündlich aktualisierte Lastprognosen

im laufenden Betrieb bereitstellen zu können.

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Energie unter dem Förderkennzeichen 0324111 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

Literatur

[1] Meisenbach, Ch.; Gnüchtel, S.: Lastprognose konventionell oder mit neuronalen Netzen – ein Vergleich. VDI Bericht Nr. 1508, 1999.

[2] Kato, K.; Sakawa, M.; Ishimaru, K.; Ushiro, S.; Shibano, T.: Heat load prediction through recurrent neural network indistrict heating and cooling systems. IEEE SMC, Singapur, Oktober 2008.

[3] Alpaydin, E.: Maschinelles Lernen. Oldenbourg Wissenschaftsverlag, München, 2008.

[4] Geron, A.: Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. O’Reilly Media, Beijing, Boston, Farnham, Sebastopol, Tokyo, 2017.

[5] Sak, H.; Senior, A.; Beaufays, D.: Long Short-Term Memory Recurrent Neural Network Architectures for Large Scale Acoustic Modeling. Google, USA, 2014.

Anzeige

bdeu akademie
mehr wissen.

Haben Sie schon an Ihre Weiterbildung gedacht?

Die BDEW Akademie hilft Ihnen gerne dabei ...

Seminare für die Energie- und Wasserwirtschaft
www.bdeu-akademie.de

- till.faber@hs-kempton.de
- matthias.finkenrath@hs-kempton.de
- johannes.gross@hs-kempton.de
- www.hochschule-kempton.de/kwk-flex