

KI-Anwendung in der Energietechnik: Einsatz maschineller Lernverfahren für die Wärmelastprognose



Projektpartner



Prof. Dr.-Ing. Matthias Finkenrath
Hochschule Kempten

Team

deepDHC

Wissenschaftliche Mitarbeiter

- Till Faber - M. Eng. (Energietechnik)
- Fabian Behrens - M. Sc. (Informatik - Game Engineering)
- Stefan Leiprecht - M. Sc. (Informatik - Game Engineering)



Projektleitung


- Prof. Dr.-Ing. Matthias Finkenrath
Institut für Energie- und Antriebstechnik
Labor für Prozesssimulation




Ausgangssituation & Überblick über Forschungsprojekte

KWKflex 2016 - 2020

„Digitaler Zwilling“ Kraftwerke



Anlageneinsatzplanung



Lastprognose mit Machine Learning

Deep Learning Workstation I



Bild: lambdalabs.com



Kraftwerksverbund Fernwärme Ulm **FUG** FERNWÄRME ULM



Bild: Fotoclub Ulm

Kraftwerkspark



Bild: Steag

Leitstand

Fernwärmenetz Ulm




Bild: FUG



deepDHC 2020 - 2023

„Untersuchung und Weiterentwicklung modernster maschineller Lernverfahren für die hochgenaue Lastprognose in Fernwärmenetzen“



Wärmebedarf

Winter

Sommer

Tageszeit

Deep Learning Workstation II



Bild: lambdalabs.com

Motivation für Erstellung von Wärmelastprognosen

- Optimierung von Anlageneinsatz bzw. Wärmebereitstellung

Ziele

- Benchmarking maschineller Lernverfahren (Prognosen bis zu 72 h im Voraus)
- Automatisierung der Prognosen & Bereitstellung über Web-Interface
- Wirtschaftliche Bewertung von Verbesserungen der Prognosegüte

Nutzen


- Identifizierung geeigneter maschineller Lernverfahren
- Einsparung fossiler Brennstoffe zugunsten erneuerbarer Energien
- Optimierung von Brennstoffbeschaffung oder Wartungsarbeiten

Wärmelastprognose ist eine zentrale Randbedingung für den wirtschaftlichen Betrieb und die Vermeidung von CO₂ Emissionen

Wärmelastgänge aus allen Fernwärmenetzen (Wohn-, Industrie- und Mischgebiete)

- Aktuelle & vergangene Lasten (bis zu 15 Jahre zurückliegend)

Beispiellastgang
über 3 Tage



Weitere Parameter:


- Wetterdaten
- kalendarische Daten (z.B. Stunde, Monat, Wochentag, Jahreszeit, Feiertag)

Umfangreiche Datenbasis zum Training, Validieren und Testen vorhanden

- Verwendung statistisch aufbereiteter Wettervorhersagen vom Deutschen Wetterdienst (DWD)
- Basis sind frei zugängliche Vorhersagen („MOSMIX“), verfügbar für ca. 5400 Standorte weltweit bis zu 10 Tage im Voraus, u.a.:
 - Temperatur und Taupunkt in 2 m Höhe,
 - Windgeschwindigkeit und -richtung,
 - Niederschlagsmenge und -art,
 - Sonnenscheindauer
 - Luftdruck
- Tägliche Archivierung der Prognosen für alle Standorte seit 2020 an der Hochschule

Hochwertige standortgenaue Wetterprognosen sind verfügbar

Analyse von Korrelationen in Bezug auf die Wärmelast (Auszug)



Korrelationskoeffizient nahe 1 oder -1: starke Korrelation
 Korrelationskoeffizient nahe 0: keine/geringe Korrelation

Parameter	Pearson (linear)	MIC (nicht-linear)
Letzte Last	0,9905	0,9309
Durchschnittliche Last der letzten 6 Stunden	0,9718	0,9010
Temperatur	-0,8304	0,5958
Jahreszeitwert (Sinus-Funktion)	-0,8218	0,7948
Taupunkt	-0,8073	0,5541
⚡ ...	⚡ ...	⚡ ...
Jahr	-0,1254	0,0613
Windrichtung	-0,0825	0,0474

Datenanalyse unterstützt Auswahl wichtiger Einflussgrößen

Aufbereitungsschritte

- Zusammenführen benötigter Daten (z.B. Last und Wetter)
- Plausibilitätsprüfung
- Korrektur fehlerhafter Daten und Vervollständigung von Datenlücken:
 - Verfahren der Imputation, z.B. über Nächste Nachbarn Klassifikation (KNN)
 - Verwendung von Nachbarwetterstationen
- Kategorisierung von Daten und Berechnung zusätzlicher Eingangsgrößen
- Ablegen der Daten in der Datenbank
- Aufteilung in Trainings-, Validierungs- und Testdaten
- Automatisierung der oben genannten Verarbeitungsschritte (stündliches Update)


Vielschichtige Aufbereitung zur Bereitstellung einer fehlerfreien Datengrundlage erforderlich

Untersuchte maschinelle Lernverfahren

1. Entscheidungsbäume

Aufteilung des Wertebereiches der Zielgröße (hier: Wärmebedarf) unter Berücksichtigung externer Einflussgrößen

Beispiel:




Einfaches & gut nachvollziehbares Verfahren

Untersuchte maschinelle Lernverfahren

2. Künstliche Neuronale Netze

Zusammenhang zwischen Daten muss vom Netz erlernt werden




**Wachsende Bedeutung durch größere Datenmengen,
höhere Rechenleistungen & verbesserte Algorithmen**

Untersuchte maschinelle Lernverfahren

3. Ensemble Methoden

Kombination mehrerer Lernverfahren („Stacking“)



Weitere Steigerungen der Prognosegenauigkeit durch Kombination verschiedener Lernverfahren erwartet

Beispiele untersuchter Verfahren

Autoregressive Verfahren

- SARIMAX (Seasonal Autoregressive Integrated Moving Average Exogenous model)

Entscheidungsbäume

- Random Forest
- AdaBoost (Adaptive Boosting)
- Extreme Gradient Boosting


Neuronale Netze

- Echo State Network (ESN)
- LSTM (Long short-term memory)

**Unterschiedliche Typologien,
Training & Vergleich für Winter, Sommer, Übergangszeit und über ein ganzes Jahr**


Beispielprognose

Vergleich einer 72 h-Vorhersage mit der tatsächlich eingetretenen Last



Prädiktionen über 72 h-Intervall mit hoher Genauigkeit möglich

Vergleich der Prognosefehler 72 h im Voraus



Lernverfahren „LSTM“ und „AdaBoost“ zeigen höchste Prognosegüten

Wirtschaftliche Auswirkungen unterschiedlicher Prognosegüten *deepDHC*

Erwartung

- Genauere Lastprognose ermöglicht wirtschaftlicheren Betrieb

Herausforderung

- Quantifizierung des Vorteils genauerer Lastprognosen ist schwierig, da sich der reale Anlageneinsatz nicht wiederholen lässt


Lösungsansatz

- Untersuchung des Einflusses unterschiedlicher Lastprognosen mittels numerischer Anlageneinsatzplanungsoptimierung:
 1. Optimierung mit gemessener Wärmelast („Referenzfall“, Optimum)
 2. Wiederholung der Optimierung mit Wärmelast mit 5 %, 10 % und 15 % aufgeprägtem mittlerem Prognosefehler

Numerische Anlageneinsatzplanungsoptimierung ermöglicht systematische Untersuchung des Fehlereinflusses


Wirtschaftliche Auswirkungen unterschiedlicher Prognosegüten *deepDHC*

Spitzenlastkessel Einsatz bei unterschiedlichen Prognosegüten





**Steigende Betriebskosten (Brennstoff, CO₂, Verschleiß, etc.)
bei steigendem Prognosefehler**

Darstellung in Webanwendung



Automatisierte Datenverarbeitung & Live-Testbetrieb auf Server der Fernwärme Ulm, Zugriff über alle Geräte (PC, Handy) aus Firmennetz möglich

Webanwendung – weitere Features



Weitere Features (Wetterdaten, Regenradar) wurden in die Webanwendung implementiert

Beispiele für Übertragbarkeit der Methodik auf andere Zeitreihen- bzw. Bedarfsprognosen

Anwendungsbeispiele:

- Wärme- / Kältebedarfsprognosen
- Strombedarfsprognosen
- Prognose des Gasverbrauches
- Rohstoffbedarf
- Maschineneinsatz
- Vorhersage von Preisentwicklungen usw.

Optimierung von:

- *Anlageneinsatz, Wartung*
- *Wärmespeichereinsatz*
- *Einkauf*
(Gas/Strom/Wärme/Rohstoffe/Waren)

Methodik ist auf viele Problemstellungen und andere Nutzerkreise übertragbar

Zusammenfassung & Ausblick

- Maschinelle Lernverfahren wurden evaluiert & besonders geeignete ermittelt.
- Die Lastprognosen laufen vollautomatisiert über ein Webinterface beim Fernwärmeunternehmen.
- Weitere Lernverfahren werden untersucht & eine Automatisierung des Lernvorgangs implementiert (“selbstlernende Verfahren”).
- Methodik ist auf viele Problemstellungen und andere Nutzerkreise übertragbar.

deepDHC



Projekthomepage: www.deepDHC.de

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

Das in diesem Vortrag zugrundeliegende Vorhaben wurde aus Mitteln des Bundesministeriums für Wirtschaft und Energie (BMWi) unter dem Förderkennzeichen 03EN3017 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

Veröffentlichungen & Patentanmeldungen



- [1] Leiprecht, S., Behrens, F., Faber, T., Finkenrath, M.: A comprehensive thermal load forecasting analysis based on machine learning algorithms, Energy Reports, Volume 7, Supplement 4, October 2021, Pages 319-326, <https://doi.org/10.1016/j.egy.2021.08.140>
- [2] Finkenrath, M., Faber, T., Behrens, F., Leiprecht, S.: Holistic modelling and optimisation of thermal load forecasting, heat generation and plant dispatch for a district heating network. 34th International Conference on Efficiency, Cost, Optimization, Simulation and Environmental Impact of Energy Systems, June 27 - July 2, 2021, Taormina, Italy
- [3] Faber, T., Finkenrath, M.: KWK-Flex - Hochflexible stromgeführte Kraft-Wärme-Kopplung durch thermische Speicher und "Power-to-Heat"-Technologien, AGFW Forschungsbericht, AGFW Projektgesellschaft für Rationalisierung, Information und Standardisierung mbH, Frankfurt am Main, 2020, ISBN 3-89999-085-4
- [4] Finkenrath, M., Faber, T.: KWK-Flex - Anwenderleitfaden für die Fernwärmebranche, Hochschule Kempten, 2020
- [5] Finkenrath, M., Faber, T.: Optimierte Wärmelastprognose mittels Deep Learning, Kraftwerkstechnik 2019, ISBN 978-3-934409-93-4, 2019
- [6] Faber, T., Finkenrath, M.: Lastprognose für Wärmenetze, 5. KWK.NRW-Forum: Perspektiven für die KWK in NRW, 2019
- [7] Faber, T., Groß, J., Finkenrath, M.: Innovative Lastprognosen mit »Deep Learning«-Methoden, EuroHeat&Power, 2018, Volume 47, 1-2, pp. 35-38
- [8] Faber, T.; Brauer, J.; Finkenrath, M.; Mayer, W.; Schott, M: Optimierung eines Querverbundsystems mittels neuronaler Netze. Europäische Patentanmeldung EP3.432.234.A1. 2017