

Künstliche Neuronale NARX-Modelle zur Wärmelastprognose von Nahwärmenetzen

G. Steindl, Ch. Pfeiffer, M. Puchegger

Forschung Burgenland GmbH, Eisenstadt, Österreich

ABSTRACT: Im Kontext des Smart Grid und der hybriden Netzbetrachtung stellen Wärmenetze eine Flexibilität für das Stromnetz bereit, die durch intelligente Nutzung eine bessere Integration der erneuerbaren Energieträger ermöglichen kann. Dafür sind Wärmelastprognosen für das Wärmenetz erforderlich, um prädiktiv die Wärmebereitstellung zu regeln. Die Stärken des NARX-Modells in Kombination mit Neuronalen Netzen liegen dabei in der Lernfähigkeit und Adaptierbarkeit des Modells. Trotz einer suboptimalen Menge an Trainingsdaten und der geringen Größe des betrachteten Nahwärmenetzes, liefert das Modell gute Prognosewerte in einem Prädiktionshorizont von bis zu 24 Stunden.

1. EINLEITUNG

Durch den Ausbau erneuerbarer Energieträger wie Windkraft und Photovoltaik kommt es durch deren Volatilität zu Situationen im Stromnetz, in denen kurzfristig Fahrpläne von Kraftwerken angepasst werden müssen, um Prognoseabweichungen auszugleichen oder Überlastungen im Stromnetz zu vermeiden. Die dadurch anfallenden Engpassmanagementkosten beliefen sich im Jahr 2016 beispielsweise auf über 150 Millionen Euro (Christiner 2017).

Je weiter der Ausbau und die Integration der erneuerbaren Energieträger voranschreitet, umso größer müssen die verfügbaren Ausgleichskapazitäten werden und umso höher werden die dadurch verursachten Kosten.

Das Problem lässt sich durch Flexibilitäten im Stromnetz reduzieren, die es ermöglichen regional erzeugten Strom auch möglichst regional zu verbrauchen oder zu speichern. Die Flexibilitäten können dabei Energieträgerübergreifend genutzt werden. Wärmenetze ermöglichen die kostengünstige thermische Speicherung bzw. Verbrauch der regionalen Stromüberproduktion. Für diese Sektorenkopplung von Wärme und Strom benötigt es effiziente Schnittstellen zwischen den Energieträgern, wie Wärmepumpen, als Ergänzung zu bestehenden Wärmeerzeugern im Wärmenetz.

Für den optimalen Einsatz dieser Wärmepumpen bedarf es einer Einsatzplanung die eng mit dem elektrischen Netz und dem dortigen Handel verbunden ist. Wärmelastprognosen für die folgenden 24 Stunden, sog. Day-Ahead-Prognosen sind dafür erforderlich.

Die Ansätze zur Modellierung des Wärmebedarfs lassen sich prinzipiell in sogenannten Forward und Data-Driven Ansätze unterscheiden (Fumo 2014). Bei den Forward-Ansätzen erfolgt eine möglichst exakte physikalische Modellierung des Systems. Die Data-Driven Ansätze versuchen mit keinem oder geringem physikalischen Hintergrund ein Modell aus bestehenden bzw. gesammelten Daten abzuleiten. Der Vorteil der datengetriebenen Modelle ist die Möglichkeit der Adaptierung wenn neue Daten verfügbar sind (Kusiak 2010).

Neben den klassischen, auf statistischen Methoden beruhenden Vorhersagemodellen, kommen auch Machine-Learning-Algorithmen zur Wärmelastprognose zum Einsatz. Wie sich aus

anderen Untersuchungen gezeigt hat, eignen sich diese Modelle zur Vorhersage des Wärmebedarfs für ein Nah- bzw. Fernwärmenetz (Steindl 2017).

Einer dieser Machine-Learning Ansätze sind Künstliche Neuronale Netze (KNN), die sich für Klassifizierungs- und Regressionsaufgaben eignen. Sie wurden bereits in unterschiedlichen Anwendungen für kurz- und langfristige Wärmelastprognosen eingesetzt (Wojdyga 2014) (Sandberg 2016). In der vorliegenden Arbeit soll die Eignung eines KNN zu nichtlinearen Funktionsapproximation in einem NARX-Model (Nonlinear Autoregressive with Exogenous Input) zur Wärmelastprognose untersucht werden.

2. METHODIK

Die wesentlichen Schritte bei der Anwendung von Machine-Learning ist die Datenidentifikation, das Sammeln der Daten sowie die Datenaufbereitung (Harrington 2012).

Die Datenidentifikation, d.h. die Bestimmung der Inputparameter des Modells erfolgt durch eine Literaturrecherche sowie explorativ, wobei der Einfluss durch Berechnung der Korrelationen verifiziert wird. Wesentlichen Einfluss auf den Wärmebedarf eines Wärmenetzes hat vor allem die Wetterlage (Yang 2015). Zusätzlich wurden kalendarische Inputparameter wie Wochentag, Uhrzeit, usw. untersucht. Diese dienen als zusätzliche Eingangsparameter des Prognosemodells (Gadd 2013).

Für die Vorhersage wird ein sog. NARX-Model eingesetzt, das einen nicht-linearen Zusammenhang zwischen vergangenen Eingängen, vergangenen Ausgängen und dem prädictierten Ausgang herstellt.

$$y(t) = f\{y(t-1) \dots y(t-n_y), u(t-1) \dots u(t-n_u)\} + e(t) \quad (1)$$

In Gleichung (1) steht $u(t)$ und $y(t)$ für die Ein- bzw. Ausgangswerte des Modells zum Zeitpunkt t . n_y und n_u bestimmen die Ordnung des dynamischen Modells ($n_u \geq 0$, $n_y \geq 1$).

Die Funktion f beschreibt die nichtlineare Funktion, die durch ein neuronales Netz approximiert wird. Zum Einsatz kommt dabei ein vorwärts gerichtetes, vollständig verbundenes Perzeptron mit einer Eingangsschicht, einer Ausgangsschicht und einem Hidden-Layer. Als Aktivierungsfunktion der Neuronen kommt in der Eingangs- und der Zwischenschicht die Rectified Linear Unit (ReLU) Funktion, wie sie in Gleichung (2) beschrieben, zum Einsatz:

$$f(t) = \max(0, x) \quad (2)$$

Die Ausgangsschicht verwendet die Sigmoidfunktion als Aktivierungsfunktion.

Die Anpassung der Gewichte der einzelnen Neuronen erfolgt mittels Adam-Optimierungsalgorithmus (Kingma 2015). Die Ausgangsschicht des KNN liefert die Stundenwerte der Wärmelastprognose für die nächsten 24 Stunden, durch eine Multi-step-Ahead-Prädiktion.

Die Validierung des Prognosemodells erfolgt mit realen Messdaten eines Nahwärmenetzes. Die Messdaten werden hierzu zufällig in ein Trainingsset und ein Validierungsset unterteilt. Zur Messung der Performanz des Prognosemodells werden der von Willmott (2005) empfohlene mittlere absolute Fehler (MAE), der mittlere prozentuelle Fehler (MAPE) sowie das Bestimmtheitsmaß R^2 herangezogen. Diese sind wie folgt definiert:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

In den Gleichungen (3), (4) und (5) ist $\hat{y}_i$ die prädizierte Wärmeleistung, y_i die tatsächlich gemessene Leistung und $\bar{y}$ der Mittelwert der gemessenen Wärmeleistung. n bezeichnet die Anzahl der prädizierten Wärmeleistungen.

3. ERGEBNISSE

Für die Validierung des Prognosemodells wurden Messdaten aus einem Nahwärmenetz mit einer Gesamtlänge von 1.860 m herangezogen. Die Topologie des Wärmenetzes ist Sternförmig und wird von einem zentralen Punkt mit Wärme versorgt. Als Wärmeerzeuger kommt ein BHKW (Blockheizkraftwerk) mit einer thermischen Nennleistung von 400 kW zum Einsatz. Zur Abdeckung der Spitzenlasten wird ein Biomassekessel mit 880 kW Nennleistung zugeschaltet.

Im Wärmenetz werden Systemtemperaturen von 90 °C im Vorlauf und 60 °C im Rücklauf gefahren. Die Wärme wird zur Heizung und Warmwassererzeugung in den Gebäuden verwendet. Hierbei handelt es sich ausschließlich um Bürogebäude, Industrie- und Gewerbeobjekte.

Nachfolgend sollen die Ergebnisse der Datenanalyse, die daraus abgeleitete NARX-Modellstruktur sowie die Ergebnisse der Modellevaluierung dargelegt werden.

3.1 DATENANALYSE

Um die wesentlichen Eingangsgrößen des Modells zu identifizieren und relevanten Parameter zu bestimmen wird eine Analyse des Wärmeleistungsbedarfs durchgeführt.

Abb. 1 zeigt den durchschnittlichen Wärmeleistungsbedarf im Nahwärmenetz für die Messperiode von einem Jahr. Wie zu erwarten ist die Wärmeabnahme im Sommer sehr gering. Im Winter liegt die maximale Leistung bei ca. 790 kW. Im Jahresschnitt liegt lediglich eine mittlere Wärmeleistung von ca. 220 kW vor.




Abb. 1: Verteilung der Wärmelast über ein Jahr

Der Wärmebedarf wurde über ein Jahr gemessen. Aufgrund des verwendeten Messsystems und den damit verbunden Übertragungsverzögerungen sowie Änderung von Parametern

während der Messung ergibt sich eine Zeitreihe mit variierenden Abtastzeiten. Diese variieren zwischen 5 und 15 Minuten. Für die weitere Analyse wurde die Zeitreihe auf eine konstante Abtastzeit von 15 Minuten durch lineare Interpolation transformiert. Da die Wetterdaten für den Standort des Nahwärmenetzes nur in einer Auflösung von einer Stunde vorhanden sind, ist die Auflösung der Prognose somit auf Stundenwerte limitiert. Die Messreihe der Wärmeleistung des Wärmenetzes wurde daher ebenfalls auf Stundenmittelwerte angepasst. Diese Zeitreihe mit äquidistanten Abtastzeitpunkten wurde in weiterer Folge zum Modelltraining und zur Validierung herangezogen.

Auf Grund von längeren Ausfällen des Messsystems fehlen Messdaten im Jahresverlauf. Diese sind in Abb. 1 durch ein „X“ dargestellt. Die Ursache für den Ausfall des Messsystems konnte nicht identifiziert werden. Die fehlenden Zeitbereiche wurden aus den Trainingsdaten entfernt.

3.2 MODELLSTRUKTUR

Die NARX-Struktur zeichnet sich durch externe Eingangsgrößen sowie einer Rückkopplung der Ausgangsgröße aus. Einen wesentlichen Einfluss auf den Wärmebedarf im Netz hat vor allem die Außentemperatur. Abb. 2 zeigt die Abhängigkeit der abgegebenen Wärmeleistung ins Netz in Bezug auf die Außentemperatur. Es lässt sich ein linearer Zusammenhang mit einem Strukturbruch bei ca. 15 °C erkennen. Dieser Zusammenhang ist vor allem bei der Bildung der Kreuzkorrelation ersichtlich. Ebenfalls zu erkennen in Abb. 2 ist ein Maximum der Korrelation bei einer Zeitverschiebung von 3 Stunden. Diese Zeitverzögerung beschreibt im Wesentlichen die thermische Trägheit der angeschlossenen Gebäudetypologie.

Für die Modellstruktur bedeutet das, dass auch zeitverzögerte Temperaturwerte von bis zu 3 Stunden, als externe Einflussgrößen berücksichtigt werden. Der neuerliche Anstieg der Autokorrelationskoeffizienten in Abb. 2 bei einer Zeitverschiebung in Richtung 24 Stunden ist durch den natürlichen Tag-Nacht-Rhythmus zu erklären.




Abb. 2: Kreuzkorrelation zwischen Außentemperatur und Wärmebedarf

Zur Bestimmung der Zeitverzögerung der Rückkopplung des NARX-Modells wird die Autokorrelationsfunktion der Wärmeleistung gebildet. Abb. 3 zeigt das Ergebnis, wobei die Korrelation bis zu einer Zeitverzögerung von 3 Stunden bei über 98 % liegt. Daher werden diese Werte im Prognosemodell berücksichtigt. Wie auch bei der Kreuzkorrelation zwischen Außentemperatur und Wärmeleistung ist der 24-Stunden Rhythmus in der Autokorrelationsfunktion zu erkennen.




Abb. 3: Autokorrelationsfunktion des Wärmebedarfs im Wärmenetz

Der Einfluss des Wochentages auf die Wärmeleistung ist in Abb. 4 dargestellt. Auch wenn dieser Effekt auf absolute Werte hin relativ gering ausfällt, ist er einer Varianzanalyse zufolge hochsignifikant ($F = 5.72$, $p < 0.01$). Die Berücksichtigung der Wochentage als externe Einflussgröße im Modell führt demnach zu einer Verbesserung der Prognoseergebnisse.




Abb. 4: Durchschnittliche Wärmeleistung pro Wochentag zwischen März und April

Eine saisonale Abhängigkeit der Wärmeleistung ist bereits in Abb. 1 zu erkennen. Um diese im Modell zu berücksichtigen, wird ein gleitender Mittelwert der Außentemperatur über die letzten 12 Stunden gebildet und als weitere Eingangsgröße im Modell berücksichtigt. Daraus lässt sich eine vereinfachte Modellstruktur wie in Abb. 5 dargestellt ableiten.




Abb. 5: Vereinfachte Modellstruktur

3.3 MODELLEVALUIERUNG

Nachfolgend sollen die Prognoseergebnisse des zuvor beschriebenen Modells evaluiert werden. Wie die Abb. 6 zeigt, hat eine Ausdehnung des Prädiktionshorizonts zunächst einen kontinuierlich ansteigenden MAPE zur Folge. Während bei gegebenem Modell im Rahmen der Vorhersage für die folgende Stunde ein MAPE von ca. 10 % vorliegt, beträgt jener einer 12-Stunden-Prognose knapp unter 16 %. Bei Betrachtung fernerer Vorhersagezeiträume von bis zu 24 Stunden verhalten sich die Modelle hinsichtlich MAPE relativ stabil, wenngleich sogar vergleichsweise geringere durchschnittliche Absolutfehler in den Vorhersagehorizonten von 19 bis 23 Stunden zu messen sind. Grund für den konstanten Fehler ist, dass bei längeren Prognosehorizonten alleine die externen Eingangsparameter wie Außentemperatur, Wochentag und 12-Stunden Mittelwerttemperatur zur Prognose herangezogen werden. Der aktuelle Wärmenetzstatus und dessen Dynamik werden dabei nicht mehr berücksichtigt.

Die angeführten Tendenzen spiegeln sich auch in der Modellgüte wider. Erwartungsgemäß ist der höchste Wert bei der Vorhersage der folgenden Stunde zu erzielen ($R^2 = 0.98$). Durch die Ausdehnung des Prädiktionshorizontes fällt diese kontinuierlich ab, bis innerhalb des Vorhersagezeitraumes von 12 bis 24 Stunden im Mittel eine Güte von 0.93 vorliegt.

Bei Betrachtung der absoluten Vorhersagefehler für bestimmte Prädiktionshorizonte erkennt man, dass die Interquartilsabstände der Modellfehler im Mittel einen relativ schmalen Bereich von 25 kW aufspannen. Bei Ausdehnung des Prädiktionshorizontes ist die Streuung der Abweichungen in marginalem Ausmaß höher. Der relative Fehler ist hier aufgrund der geringen Größe des Nahwärmenetzes und des damit verbunden geringen Leistungsbedarfs größer.




Abb. 6: Vergleich der Prognoseabweichungen verschiedener Prädiktionshorizonte

Für die nachfolgenden Analysen werden die 2-Stunden- und 24-Stunden-Prognosen herangezogen. Die 24-Stunden-Prognose ist auf Grund der Sektorenkopplung mit dem Stromnetz und dem damit verbundenen Day-Ahead-Handel am EPEX-Spot von Bedeutung.

Abb. 7 zeigt Auszüge des Wärmebedarfs im Rahmen von 4-Tages-Perioden im Winter sowie im Sommer. Dabei wird die Wärmeleistung für Werktage (Sonntag 22:00 Uhr bis Donnerstag 22:00 Uhr) anhand der Winter-Periode sowie mit Berücksichtigung des Wochenendes anhand

der Sommer-Periode (Freitag 22:00 Uhr bis Dienstag 22:00 Uhr) samt Prognosen für 2-Stunden- und 24-Stunden-Zeithorizonte dargestellt.

In der dargestellten Winter-Periode erreicht der Wärmebedarf im vorliegenden Netz täglich gegen 10:00 Uhr seine Spitzen mit über 500 kW, während im Zeitrahmen zwischen 18:00 und 22:00 Uhr Täler mit rund 300 kW festzustellen sind. An Werktagen verhält sich die 2-Stunden-Prognose in ihrer Amplitude adäquat, während die 24-Stunden-Prognose einige Ausschläge deutlich verfehlt. Zudem sind kurzfristige Schwankungen auf Stundenbasis in beiden Modellen nicht darstellbar.




Abb. 7: Vergleich des tatsächlichen Wärmelastbedarfs mit Vorhersagen für 2 Stunden und 24 Stunden

Die illustrierte Wärmeleistung in den Sommertagen inklusive Woche ist durch fehlende Periodizität charakterisiert, wenngleich die Spannweite der auftretenden Schwankungen mit rund 40 kW weitaus geringer als im Winter ausfällt. Die kurzfristige 2-Stunden-Prognose weist hierbei unregelmäßige Unschärfen auf. Zwar werden vor allem kurzfristige Schwankungen vom Modell erneut nicht erfasst, dennoch wird die Struktur der Wärmeleistung grundsätzlich gut nachgebildet. Das 24-Stunden-Prognosemodell korreliert nur ansatzweise mit der tatsächlichen Lastkurve.

4. SCHLUSSFOLGERUNG, ZUSAMMENFASSUNG

Der Ausfall des Messsystems und der damit verbundene Datenverlust über längere Zeiträume während der Messperiode wirken sich negativ auf die Prognosequalität aus. In weitere Folge ist daher zu untersuchen, inwieweit die Prognose durch zusätzliche Daten verbessert werden kann.

Der begrenzte Umfang des betrachteten Nahwärmenetzes, welches zur Modellvalidierung diente, wirkt sich negativ auf die dargestellten Ergebnisse aus. Dies liegt daran, dass die Stochastik des Wärmebedarfs im Gegensatz zu großen Fernwärmenetzen steigt. Außerdem erhöht sich der relative Fehler durch den generell geringen Leistungsbedarf im Netz.

Die Validierung zeigt, dass der mittlere prozentuelle Fehler mit zunehmendem Prognosehorizont steigt und ab ca. 12 Stunden konstant bleibt. Dies ist darauf zurückzuführen, dass die Rückkopplung des aktuellen Netzzustands bei diesen langen Prognosehorizonten keinen Ein-

fluss mehr hat. Die prognostizierten Werte werden dann nur durch die externen Eingangsparameter wie Außentemperatur, Wochentag und 12-Stunden Temperaturmittelwert bestimmt.

Trotzdem zeigen die vorgelegten Ergebnisse, dass sich NARX-Modelle mit Künstlichen Neuronalen Netzen als Prognosemodelle eignen. Die Stärke dieses Modellansatzes liegt vor allem in der Lernfähigkeit solcher Systeme. Die Prognosequalität steigt mit zunehmender Anzahl an Messdaten und kann daher während des Einsatzes weiter verbessert werden. Außerdem kann sich das Modell bei einer Änderung der Abnehmerstruktur selbst anpassen.

Weitere Untersuchungen der Modellperformanz für Kurzzeitprognosen mit einer Auflösung von 15 Minuten werden angestrebt. Hierfür sollen weitere Einflussparameter wie zum Beispiel die solare Einstrahlung untersucht und in das Modell eingebunden werden. Die Lastprognose soll in weiterer Folge zur Einsatzoptimierung der Wärmeerzeuger bzw. der Nutzung der Flexibilität im Stromnetz dienen.

5. DANKSAGUNG

Die vorliegende Arbeit wurde im Zuge des Projektes *Hybrid Grids Demo* erstellt. Dieses Projekt wird aus Mitteln des Klima- und Energiefonds gefördert und im Rahmen des Programms „Smart Cities Demo“ durchgeführt.

LITERATUR

- Chrisitner, G. (2017) Das Stromsystem im Wandel - die Sicht des Übertragungsnetzbetreibers. Austrian Power Grid (APG), 10. Internationale Energiewirtschaftstagung IEWT.
- Fumo, N. (2014) A review on the basics of building energy estimation. Renewable and Sustainable Energy Reviews Vol. 31, pp 53-60.
- Gadd, H., Werner, S. (2013): Daily heat load variations in Swedish district heating systems. Applied Energy Vol. 106, pp 47-55
- Harrington, P. (2012) Machine Learning in Action. Greenwich; CT: Manning Publications Co.
- Kingma, D. P., Ba, J. (2015) Adam: A Method for Stochastic Optimization. 3rd International Conference for Learning Representations, San Diego.
- Kusiak, A., Li, M., Zhang, Z. (2010) A data-driven approach for steam load prediction in buildings. Applied Energy Vol. 87, pp 925-933.
- Sandberg, A., et al. (2016) An analyze of long-term hourly district heat demand forecasting of a commercial building using neural networks. The 8th International Conference on Applied Energy – ICAE2016.
- Steindl, G., Pfeiffer, Ch. (2017) Comparison of Black Box Models for Load Profile Generation of District Heating Networks, 12th Conference on Sustainable Development of Energy, Water and Environment Systems - SDEWES2017
- Willmott, C. J., Matsuura, K. (2005) Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. Climate Research Vol. 30, pp 79-82.
- Wojdyga, K. (2014) Predicting heat demand for a district heating systems. International Journal of Energy and Power Engineering Vol. 3(5), pp 237-244.
- Yang H. et al. (2015) Heat Load Forecasting of District Heating System Based on Numerical Weather Prediction Model. 2nd International Forum on Electrical Engineering and Automation, IFEEA.
-

Kontakt Daten Autor(en):

DI DI Gernot Steindl

Campus 1

7000 Eisenstadt

Email: gernot.steindl@forschung-burgenland.at