

Vergleich von Machine Learning Algorithmen zur Modellierung von Nahwärmenetzen

Gernot Steindl und Christian Pfeiffer

Forschung Burgenland GmbH, Campus 1, 7000 Eisenstadt, Austria
gernot.steindl@forschung-burgenland.at
christian.pfeiffer@forschung-burgenland.at

Abstract.

Machine Learning Algorithmen erlauben es sehr schnell und effizient Modelle für Nahwärmenetze zu generieren und damit den Wärmebedarf zu simulieren. Grundvoraussetzung ist die Verfügbarkeit an qualitativ guten Messdaten über einen längeren Zeitraum. Mit der in der Arbeit abgeleiteten Modellstruktur wurden fünf unterschiedliche Machine Learning Algorithmen, nämlich Multiple Lineare Regression (LR), Support Vector Regression (SVR), Random Forest (RF), k-Nearest Neighbor (k-NN) und Artificial Neural Networks (ANN), in Bezug auf ihre Modellgüte zur Wärmelastmodellierung eines Nahwärmenetzes untersucht. Mit Ausnahme der LR zeigten alle Algorithmen gute Ergebnisse, wobei der k-NN Algorithmus die geringsten Fehlerraten aufwies.

Keywords: Wärmenetz, Wärmelasten, Machine Learning, Black Box Modell

1 Einführung

Der Ausbau erneuerbarer Energieträger wie Wind und Photovoltaik führt zu einer verstärkten Volatilität der Stromerzeugung, da diese Energieträger in der Produktion nur begrenzt planbar bzw. steuerbar sind. Da der aktuelle Leistungsbedarf im Stromnetz zu jedem Zeitpunkt durch die Erzeugung gedeckt werden muss, führt ein hoher Anteil an fluktuierenden erneuerbaren Energieträgern zu Stabilitätsproblemen bzw. hohen Regel- und Ausgleichsenergiekosten.

Wärmenetze ermöglichen die kosteneffiziente, thermische Speicherung der volatilen, erneuerbaren Energien. Dazu bedarf es effizienter Schnittstellen zwischen dem Strom- und Wärmesektor, zum Beispiel in Form von Hochtemperaturwärmepumpen sowie neuer Regelstrategien für das hybride Energiesystem. Diese werden im ersten Schritt durch Simulationsstudien untersucht. Für diese Untersuchungen bedarf es Simulationsmodelle, die neben der Erzeugung auch den Verbrauch im Wärmenetz abbilden. Dabei kommen grundsätzlich zwei Ansätze bei der Modellierung zur Anwendung, nämlich „Forward“ und „Data-Driven“ Modelle [1].

Bei Forward-Modellen oder auch White-Box Modellen werden mathematische Gleichungen benutzt, um das physikalische Verhalten nachzubilden. Diese Modelle können sehr komplex sein und sind für die Modellierung des Lastverhaltens im Wärmenetz nur bedingt geeignet.

Data-Driven oder Black-Box Modelle werden rein aus vorhandenen Daten erstellt. Eine physikalische Interpretation der Modelle ist somit in der Regel nicht mehr möglich. Eine Möglichkeit der Bildung dieser Black-Box Modelle stellen Machine Learning Algorithmen dar. Die Anzahl und Qualität der vorhandenen Daten ist dabei entscheidend für die Modellgüte. Datengetriebene Modelle haben den Vorteil, dass diese mit neuen Daten adaptiert und upgedatet werden können [2]. Ebenfalls entscheidend für die Modellgüte ist die Wahl der richtigen Input-Features. Untersuchungen zeigen, dass das Wetter sowie das soziale Verhalten den größten Einfluss auf den Wärmebedarf eines Gebäudes hat [3]. Die Außentemperatur sowie die Luftfeuchte korrelieren dabei am meisten mit dem Wärmebedarf im Wärmenetz [4].

Die vorliegende Arbeit gibt einen Überblick über unterschiedliche Machine Learning Algorithmen, die zur Erstellung von Black-Box Wärmenetzmodellen eingesetzt werden und deren Eignung zum Einsatz für Simulationstools in Form von Modellgütemetriken.

2 Methodik

Die wesentlichen Schritte beim Einsatz von überwachten Machine Learning Algorithmen sind die Datenidentifikation, die Datensammlung sowie die Datenaufbereitung [5].

Die Datenidentifikation, d.h. die Frage nach den Input-Features erfolgte einerseits durch eine Literaturrecherche, um die notwendigen Messdaten zu identifizieren, andererseits durch eine Parametervariation. Zu viele Input-Features können zu einem Übertrainieren der Modelle führen, was zu einer schlechten Generalisierbarkeit der Modelle führt. Daher wird die Anzahl der Eingangsparameter so gering wie möglich gewählt. Die Auswahl erfolgt mit Hilfe von statistischen Methoden wie Auto- und Kreuzkorrelationen sowie Box-Plots.

Die Datenakquise erfolgte mit Wärmemengenzählern, die mittels M-Bus periodisch ausgelesen wurden und zentral gespeichert wurden. Aufgrund des Messsystems variierten die Abtastzeiten zwischen 5 und 15 Minuten. Bei der Datenaufbereitung wurden daher die Abtastintervalle der Messreihe angeglichen.

Die Wetterdaten wurden mit einer Auflösung von einer Stunde von der Zentralanstalt für Meteorologie und Geodynamik (ZAMG) [6] für das Gebiet eines Nahwärmenetzes erfasst.

Mit den identifizierten Input-Features wurde eine Modellstruktur abgeleitet. Mit dieser Struktur wurden folgende fünf Machine Learning Algorithmen implementiert: Multiple Linear Regression (LR) [7], Support Vector Regression (SVR) [8,9], Random Forest (RF) [10,11], k-Nearest Neighbor (k-NN) [12,13] und Artificial Neural Networks (ANN) [14,15].

Um die Modellgüte der Algorithmen vergleichen zu können wurden der Mean Absolute Error (MAE), der Mean Absolute Percentage Error (MAPE) sowie das Bestimmtheitsmaß R^2 herangezogen. Diese sind wie folgt definiert:

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

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

\hat{y}_i ist die vorhergesagte Wärmeleistung, y_i ist die tatsächlich aufgetretene Wärmeleistung, \bar{y} ist der Mittelwert der beobachteten Wärmeleistungen und n ist die Anzahl der vom Modell berechneten Werte.

Neben den oben beschriebenen Metriken wurde die Jahresdauerkennlinie herangezogen, um die Modellgüte in Spitzen- und Schwachlastphasen beurteilen zu können.

3 Ergebnisse

3.1 Datenanalyse

Gegenstand der Untersuchung bildet ein relativ kleines Nahwärmenetz mit einer Länge von rund 1.860 m. Das Netz ist zur Bereitstellung einer Vorlauftemperatur von 90 °C und einer Rücklauftemperatur von 60 °C ausgelegt. Das gesamte Netz wird von einem zentralen Blockheizkraftwerk (BHKW) mit einer thermischen Nennleistung von rund 400 kW versorgt. Zur Abdeckung von Spitzenlasten wird ein Biomassekessel mit einer Nennleistung von 880 kW verwendet. Die erzeugte Wärme steht zur Beheizung und Warmwasseraufbereitung der angebundenen Gebäude zur Verfügung.

Da es sich bei diesen Gebäuden hauptsächlich um Bürogebäude handelt, ist der Warmwasserverbrauch während des gesamten Jahres typischerweise gering. Auch der Heizbedarf fällt in den Sommermonaten erwartungsgemäß gering aus. In der einjährigen Messperiode wurde ein maximaler Wärmebedarf von rund 790 kW festgestellt, während der mittlere Verbrauch nur 220 kW beträgt.

Die Wärmeleistung wurde in Zeitschritten von rund 5 bis 15 Minuten gemessen. Bedingt durch den Aufbau des Messsystems führten Verzögerungen bei der Datenübertragung zum Erhalt von nicht äquidistanten Zeitschritten, die im Vorfeld der Analyse entsprechend vereinheitlicht werden mussten. Diesbezüglich erfolgte eine Transformation der Daten auf linear interpolierte 15-Minuten-Schritte. Die bereinigte Zeitreihe wurde für die weiteren Analysen sowie als Trainingsdatensatz für die Modelle verwendet. Zur Schätzung des stündlichen Wärmebedarfs des Netzes mithilfe der vorgestellten Algorithmen wurden die Mittelwerte auf Stundenbasis berechnet und als Modellinput herangezogen.

Zudem führten einige nicht näher bekannte Fehler des Messsystems zum Verlust einiger Daten. Während kurze fehlende Messperioden bis zu einer Stunde mittels linearer Interpolation rekonstruiert wurden, wurden längere Intervalle fehlender Werte als solche markiert und für die Modellbildung nicht weiter berücksichtigt.

3.2 Modellstruktur

Zum Modelltraining wurden lokale Wetterdaten wie Temperatur, Luftfeuchtigkeit und Windstärke herangezogen. Zur Untersuchung des Einflusses der gewählten Inputparameter wurden Kreuzkorrelationen zwischen den Wetterdaten und dem Wärmebedarf ermittelt. So ist bei der Zielvariable eine hohe negative Korrelation mit der Temperatur ($R(3) = -0,90$) und eine moderate positive Korrelation mit der Luftfeuchtigkeit ($R(3) = 0,32$) festzustellen. Dass die höchsten Korrelationskoeffizienten jeweils bei einem Lag von drei Stunden auftreten, kann mit der thermischen Trägheit der am Nahwärmenetz angeschlossenen Gebäude erklärt werden. Hinsichtlich der Windstärke konnte kein nennenswerter Einfluss auf den Wärmebedarf festgestellt werden.

Neben den Wetterdaten wurden mit dem Wochentag und dem Monat weitere kalendarische Einflussgrößen herangezogen. Während der im Jahresverlauf aufgrund saisonbedingter Außentemperaturen schwankende Wärmebedarf offensichtlich ist, wurde die Variation des Wärmebedarfs im Wochenverlauf näher untersucht. So konnte mithilfe einer Varianzanalyse ein signifikanter Einfluss des Wochentags auf den Wärmebedarf ($F = 5.72$, $p < 0,01$) nachgewiesen werden. Hierbei ist ein reduzierter Bedarf an Wochenendtagen festzustellen, der mit der Gebäudenutzung als Büroräumlichkeiten erklärbar ist.

Somit fungieren die Temperatur, Luftfeuchtigkeit sowie Wochentag und Monat als Input für die Modellierung des Wärmebedarfs. Aufgrund der höchsten Korrelation bei einem Lag von drei Stunden wird neben der aktuellen Temperatur und Luftfeuchtigkeit auch die zeitverzögerten Inputgrößen im Modell berücksichtigt.

3.3 Modellevaluierung

Anhand dieser Black-Box Modellstruktur wurden verschiedene Machine Learning Algorithmen evaluiert. Der RF wurde mit 500 Bäumen konstruiert. Das ANN wurde als Feed-Forward-Netz mit drei Hidden Layer bestehend aus acht, fünf und drei Neuronen konzipiert. Der k-NN erzielte die besten Ergebnisse unter Berücksichtigung von lediglich zwei Nachbarn.

Die Tabelle 1 zeigt den Vergleich der verwendeten Algorithmen unter Verwendung von drei statistischen Gütemaßen. Darin ist ersichtlich, dass das k-NN Modell die RF, SVR und ANN Modelle in sämtlichen Gütekriterien übertrifft, wohingegen das LR Modell mit Abstand am schlechtesten abschneidet. Im Winter und im Herbst sind, bedingt durch allgemein höhere Wärmebedarfe, vergleichsweise hohe MAE-Werte festzustellen. Der MAPE verdeutlicht, dass trotz der hohen MAE die Prognosen für die Wintermonate am genauesten sind.

Demgegenüber sind im Frühling und Sommer geringere MAE-Werte zu vernehmen. Bei genauerer Betrachtung der MAPE-Werte werden jedoch die auftretenden Ungenauigkeiten der Schätzungen deutlich. Erwartungsgemäß verhält sich vor allem das LR Modell im Sommer durch seine Tendenz zum Mittelwert fehlerhaft. Abgesehen davon scheint der Frühling jene Jahreszeit zu sein, in der Wärmebedarfe am schwierigsten nachzubilden sind.

Table 1. Vergleich der Modelle

Metrik	Algorithmus	Winter	Frühling	Sommer	Herbst	Gesamt
MAE	LR	46,83	30,94	18,88	43,44	34,64
	RF	36,44	27,08	9,57	38,23	27,86
	SVR	41,97	25,70	9,69	40,77	29,22
	ANN	39,51	26,59	9,51	39,24	27,91
	k-NN	33,58	25,04	7,87	32,11	24,74
MAPE (%)	LR	12,17	23,83	33,98	16,62	21,87
	RF	9,16	19,76	17,27	14,72	15,76
	SVR	10,65	18,39	17,78	14,87	15,77
	ANN	9,94	19,58	17,12	14,92	15,85
	k-NN	8,64	17,77	13,99	11,49	13,49
R ²	LR	0,77	0,79	0,71	0,83	0,93
	RF	0,86	0,82	0,83	0,85	0,94
	SVR	0,81	0,83	0,82	0,84	0,94
	ANN	0,83	0,84	0,83	0,85	0,94
	k-NN	0,86	0,83	0,85	0,89	0,95

Abbildung 1 zeigt die Genauigkeit der RF und k-NN Modelle in einem einwöchigen Testzeitraum im Winter und Frühling. Die Graphen verdeutlichen die geringere Präzision des RF (gestrichelte hellgraue Linie) im Vergleich zum k-NN (gepunktete dunkelgraue Linie) in beiden Testwochen.

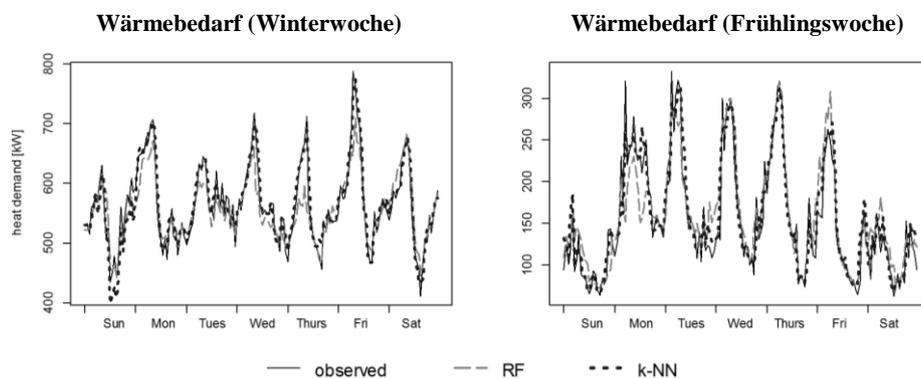


Fig. 1. Gemessener und geschätzter Wärmebedarf einer Woche im Winter und Frühling

Im Winter scheitert das RF Modell an der Schätzung der Spitzenlasten und tendiert dazu, den mittleren Wärmebedarf zu unterschätzen. Im Vergleich zu den anderen Modellen ist der k-NN Algorithmus hinsichtlich der betrachteten Gütekriterien jenes mit der größten Präzision, zumal die im Winter gemessenen Wärmelasten sehr gut getroffen werden. Dennoch ist im Falle geringerer Wärmelasten im Winter eine gewisse Unschärfe festzustellen. Zum einen wird der Wärmebedarf am Sonntag der Testwoche vom k-NN Modell stark unterschätzt, zum anderen ignoriert das Modell die Täler bei geringerem Wärmebedarf von Montag bis Donnerstag. Die Testwoche im Frühling zeigt ein eher volatiles Verhalten des RF Modells ohne eindeutigen Trend

zur Über- oder Unterschätzung des Wärmebedarfs. Im Gegensatz dazu verhält sich das k-NN Modell im Frühling wiederum treffsicherer. Trotzdem weichen einige Schätzungen weiterhin von den tatsächlichen Messpunkten ab, sodass die dargestellten Fehlerraten bestätigt werden können.

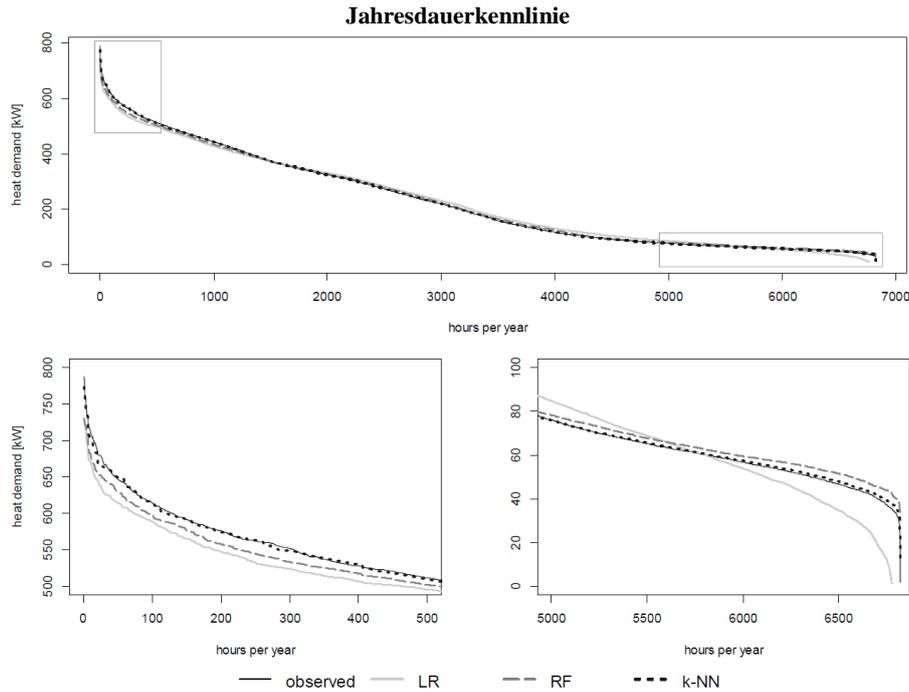


Fig. 2. Jahresdauerkennlinie inklusive Spitzen- und Schwachlastphasen

Die Jahresdauerkennlinie des betrachteten Wärmenetzes mit den kumulierten Schätzungen der LR, RF und k-NN Modelle ist in der Abbildung 2 dargestellt. Aufgrund einiger fehlender Werte sind in dieser Dauerlinie lediglich rund 6.800 Stunden berücksichtigt. Neben einigen Spitzenlasten von etwa 800 kW ist für rund die Hälfte des betrachteten Zeitraums ein Energieverbrauch von 200 kW oder geringer zu vernehmen. Wie in der linken unteren Grafik hervorgehoben wird, sinkt der Wärmebedarf innerhalb von 100 Stunden rapide ab.

Die gegebene Spitzenlast kann lediglich vom k-NN Modell adäquat abgegriffen werden. Vor allem die LR, aber auch der RF erreichen mit Ihren Schätzungen nicht die erforderlichen Werte in Spitzenlastphasen in angemessener Weise. In der rechten unteren Grafik sind Wärmebedarfe in Phasen der Schwachlast des Netzes dargestellt. Wie erwartet überschätzt das LR Modell diese Schwachlastphasen relativ lange, um dann abrupt unter die tatsächlichen Messwerte abzufallen. Hierbei werden sogar negative Wärmebedarfe geschätzt. Das RF Modell überschätzt dabei den Wärmebedarf im gesamten Schwachlastbereich. Der k-NN Algorithmus zeigt lediglich eine marginale Überschätzung bei Betrachtung der geringsten Wärmelasten.

4 Zusammenfassung

Alle untersuchten Modelle mit Ausnahme der LR zeigten gute Ergebnisse bei der Modellvalidierung. Die resultierenden Fehlerraten bewegen sich in einem ähnlichen Bereich, wobei der k-NN Algorithmus die geringsten Fehlerwerte aufweist. Es zeigte sich auch, dass die Modellgüte über das Jahr variiert, was für weitere Untersuchungen berücksichtigt werden muss.

Beim Vergleich der realen mit den simulierten Jahresdauerkennlinien des Nahwärmenetzes, konnte auch die Performanz der Modelle im Spitzen- und Schwachlastbereich gut dargestellt werden. In diesem Bereich ergeben sich die größten Schwierigkeiten für die Modelle exakte Vorhersagen zu liefern. Vor allem die LR weist hier besondere Schwächen auf, wohingegen der k-NN nur geringe Abweichungen zeigt.

Das Nahwärmenetz, das zur Modellvalidierung herangezogen wurde, besitzt nur eine geringe Anzahl von Teilnehmern. Stochastische Einflüsse wirken sich daher stärker auf die Gesamtwärmelast im Netz aus als bei großen Fernwärmenetzen. Dies führt zu schlechteren Ergebnissen der Fehlermaße. Auch die geringe Anzahl an Trainingsdaten beeinflusst die Modellgüte negativ.

Trotzdem konnte gezeigt werden, dass der Einsatz von Machine Learning Algorithmen eine effiziente Methode bei der Modellierung von Fernwärmenetzen darstellt. Voraussetzung dafür ist jedoch eine ausreichend hohe Anzahl an Trainingsdaten, die für die Modellbildung zur Verfügung stehen.

References

1. Fumo, N.: A review on the basics of building energy estimation. *Renewable and Sustainable Energy Reviews* 31, 53-60 (2014).
2. Kusiak, A., Li, M., Zhang, Z.: A data-driven approach for steam load prediction in buildings. *Applied Energy* 87, 925-933 (2010).
3. Arvastson, L.: Stochastic modelling and operational optimization in district-heating systems. PhD Thesis, Mathematical Statistics, Lund University, Lund, Sweden (2001).
4. Yang, H. et al.: Heat Load Forecasting of District Heating System Based on Numerical Weather Prediction Model. 2nd International Forum on Electrical Engineering and Automation IFEEA, pp 1-5 (2015).
5. Harrington, P.: *Machine Learning in Action*. Manning Publications Co, Greenwich, CT (2012).
6. Zentralanstalt für Meteorologie und Geodynamik (ZAMG), <http://www.zamg.ac.at>
7. Draper, N.R., Smith, H.: *Applied Regression Analysis*, John Wiley & Sons, New York (1998).
8. Breiman, L.: Random Forests. *Machine Learning* 45, 5-32 (2001).
9. Dudek, G.: Short-Term Load Forecasting Using Random Forests. In: *Proceedings of the 7th IEEE International Conference Intelligent Systems IS'2014*, pp 821-828 (2014).
10. Vapnik, V., Golowich, S., Smola, A.: *Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing*. *Advances in Neural Information Processing Systems* 9, 281-287. MIT Press, Cambridge, MA (1997).

11. Chen, B.-J., Chang, M.-W., Lin C.J.: Load Forecasting using Support Vector Machines: A Study on EUNITE Competition 2001. *IEEE Transactions on Power Systems* 19(4), 1821-1830 (2004).
12. Bishop, C. M.: *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford (1997).
13. Hayati, M., Shirvany, Y.: Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region. *International Journal of Electrical, Computer, and Systems Engineering* 1(2), 121-125 (2007).
14. Yakowitz, S.: Nearest-Neighbour Methods for Time Series Analysis. *Journal of Time Series Analysis* 8(2), 235-247 (1987).
15. Al-Qathani, F. H., Crone, S. F.: Multivariate k-Nearest Neighbour Regression for Time Series data – a novel Algorithm for Forecasting UK Electricity Demand. In: *Proceedings of International Joint Conference on Neural Networks*, pp 228-235 (2013).