

Wärmebedarf komplexer Liegenschaften

Prognosen mit künstlichen neuronalen Netzen – Teil 1



Bei KWK-Anlagen ergibt sich häufig die Situation, dass die Stromerzeugung vorhergesagt werden soll, aber die Anlagen wärmegeführt betrieben werden. Dafür ist in erster Linie eine akkurate Kenntnis des Wärmebedarfs erforderlich. Dieser kann bei komplexen Standorten von sehr unterschiedlichen Einflüssen abhängen. Im vorliegenden Teil 1 werden zunächst die Grundlagen beschrieben, um eine Methode zur jährlichen Wärmebedarfsprognose mittels künstlicher neuronaler Netze (KNN) zu entwickeln.

Dr. Jörg Hermsmeier¹,
 Christoph Kausch^{2*},
 Gregor Koletzke³,
 Dr. Stella Schraps⁴

¹EWE AG, D-26122 Oldenburg,

²perpendo Energie- und
 Verfahrenstechnik GmbH,
 D-52066 Aachen,

³EWE AG, D-26122 Oldenburg,

⁴perpendo Energie- und
 Verfahrenstechnik GmbH,
 D-52066 Aachen

Die optimierte und integrierte Energieversorgung gewinnt im Zuge der Forderung nach höherer Energieeffizienz und dadurch zunehmend komplexerer Systeme bei schwankenden wirtschaftlichen und technischen Randbedingungen stetig an Bedeutung. Eine detaillierte wirtschaftliche Bewertung eines Konzeptes oder eine ökonomische Einsatzoptimierung lassen sich bei Systemen, in denen Wärme und Strom gekoppelt produziert und verbraucht werden, oft nur durch gezielte Simulationen der Versorgungssysteme realisieren. Solche Berechnungen können nur dann erfolgreich angewendet werden, wenn die Bedarfsrandbedingungen möglichst genau und in hoher zeitlicher Auflösung bekannt sind. Dies kann grundsätzlich eine Vielzahl von Systemen betreffen, insbesondere wenn diese thermische Kältemaschinen, Kraftwärmekopplung (KWK) oder Wärmepumpen beinhalten.

Im Folgenden wird eine Prognosemethode für den Wärmebedarf entwickelt und am Beispiel eines Wärmecontractings für eine weit ausgedehnte und komplexe Liegenschaft in Oldenburg bewertet. Die EWE AG betreibt an dem Standort Uhlhornsweg der Carl von Ossietzky Universität Oldenburg die Wärmeversorgung mittels BHKW und Heizkesseln. In den BHKW soll zur Sicherstellung der erlösoptimierten Betriebsweise Biogas zum Einsatz kommen, da sich die Teilnahme an der Direktvermarktung von EEG-Strom lukrativer gestaltet als die Vergütung nach dem

Kraft-Wärme-Kopplungsgesetz. Für die technoökonomische Bewertung ist daher einerseits eine langfristige Prognose des Stromertrags notwendig, während für den Handel mit Strom am Day-Ahead-Markt eine kurzfristige Prognose benötigt wird. Da die BHKW wärmegeführt betrieben werden, ist die Stromerzeugung im Wesentlichen vom Wärmebedarf abhängig, und somit ist als erster Schritt eine möglichst gute Prognose des Wärmebedarfs das Ziel.

In der Regel ist bei komplexen Randbedingungen, wie der Wärmeversorgung einer größeren Anzahl unterschiedlicher Gebäude, ein physikalisch definiertes Modell für den Wärmebedarf zu aufwendig. Es wird stattdessen auf künstliche neuronale Netze (KNN) zurückgegriffen, da hiermit ein Zusammenhang auf der Basis vorhandener Daten beschrieben werden kann, ohne diesen Zusammenhang explizit zu kennen oder physikalisch erklären zu müssen. In der Literatur findet sich die vermehrte Anwendung von KNN zur Strombedarfsprognose [1] oder vereinzelt zur Tagesprognose des Wärmebedarfs von Wohngebäuden [2], allerdings ist nach bestem Wissen der Autoren die Entwicklung und Anwendung der hier beschriebenen Systematik zur Wärmebedarfsprognose für komplexe Liegenschaften neuartig.

Es wird untersucht, wie der Zusammenhang zwischen den Einflussgrößen und dem Wärmebedarf aussieht, also welche Randbedingungen und Inputparameter (Wetter, Tag, Uhrzeit etc.) für den Wärmebedarf wesentlich bzw. notwendig sind. Daraus wird eine Methode zur jährlichen Wärmebedarfsprognose mittels KNN entwickelt, indem in einem ersten Schritt für die Problemstellung eine kleine Anzahl geeigneter neuronaler Netztopologien identifiziert wird. Mit diesen ausgewählten KNN-Topologien werden verschiedene Trainingsintervalle verglichen und daraus eine allgemeine Systematik entwickelt, mit der diese Netze zu trainieren sind. Das erfolgreichste erzeugte KNN wird anschließend zur Wärmebedarfsprognose eines Durchschnittsjahres auf Basis eines mittleren Wetterdatensatzes herangezogen. Dieses Durchschnittsjahr kann so neben historischen Daten zur techno-ökonomische Bewertung genutzt werden.

In einem nachgelagerten Schritt wird die Methode erweitert, um auf Basis von Wetterprognosen und aufgezeichneten Verbrauchsdaten kurzfristige Wärmebedarfsprognosen für den Day-Ahead-Handel zeitnah erstellen zu können.

Grundlagen KNN

Künstliche neuronale Netze wurden historisch in Anlehnung an das menschliche Gehirn entwickelt. Sie bestehen aus einer Verknüpfung mehrerer Neuronen, wo die Kombination der Signaleingänge eines Neurons in Abhängigkeit einer Aktivierungsfunktion einen Signalausgang beeinflusst [3], [4]. Neuronen werden unterteilt in Input-, Hidden- und Output-Units,

die entsprechend ihrer Bezeichnung entweder Signaleingänge, -ausgänge oder auch beides haben. Units werden mit Kanten verbunden, die jeweils ein Gewicht haben. Die Linearkombination des Signals mit dem Gewichtungsfaktor dient dann als Inputsignal für das nächste Neuron. Die Gewichte werden mittels Trainings stetig angepasst. Das Training eines Netzes soll es dazu bringen, für ein bestimmtes bekanntes Eingangsmuster ein zugehöriges Ausgangsmuster zu erzeugen. Das „Wissen“ der Netze ist also in den Gewichten enthalten, die wiederum durch Training angepasst werden.

Der **Output** (Aktivitätslevel) eines Neurons hängt vom **Input** (Signal x Gewicht) ab und wird durch die **Aktivierungsfunktion** beschrieben. Als Aktivierungsfunktion können beliebige lineare, binäre oder Sigmoidfunktionen verwendet werden. Häufig werden die Tangens-Hyperbolicus-Funktion oder die logistische Funktion (beides Sigmoidfunktionen) verwendet.

In der Trainingsphase werden anhand von ausreichend großen Datensätzen mittels unterschiedlicher Ansätze und Algorithmen die Gewichte zwischen den Neuronen modifiziert. Es gibt eine Vielzahl unterschiedlicher Lernstrategien, die hier nicht näher erläutert werden. Ein häufig verwendetes Verfahren, das auch hier zum Einsatz kommt, ist die Fehlerrückkopplung oder Backpropagation, wobei auf Grund des Fehlers zwischen ausgegebenem und tatsächlichem Wert die Gewichte so verändert werden, dass der Fehler kleiner wird. Anhand zusätzlicher Datensätze (nicht in den Trainingsdaten enthalten) kann der Lernerfolg des Netzes überprüft werden. Typischerweise sollten ca. 20 % eines Datensatzes zur Validierung abgespalten werden.

Randbedingungen

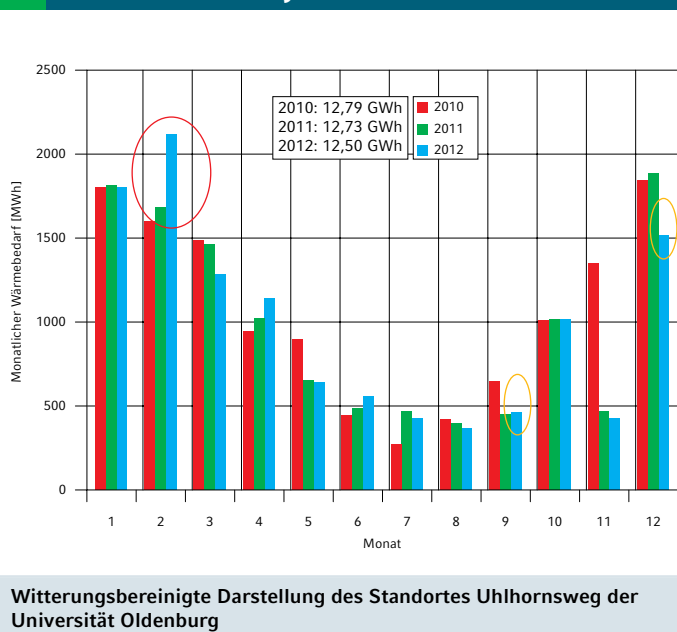
Da der Zusammenhang zwischen den Einflussgrößen und dem Wärmebedarf untersucht wird, sind also sämtliche Randbedingungen und Inputparameter (Wetter, Tag, Uhrzeit etc.), die betrachtet werden sollen, sowie der zugehörige Wärmebedarf als gleichartige Zeitreihen notwendig. Mit diesen Datensätzen können dann unterschiedlichste neuronale Netze trainiert und validiert werden und so geeignete Netztypologien mit unterschiedlichen Inputs analysiert werden.

Es werden historische Wetterdaten der Universität Oldenburg verwendet. Die Wetterdaten weisen jedoch in einigen Bereichen Fehlstellen oder unphysikalische Werte auf. Sofern es sich um einzelne Werte handelte, wurden diese Werte interpoliert. Bei Fehlstellen über mehrere Stunden wurden diese Bereiche für alle Parameter entfernt, um einen konsistenten vollständigen stündlichen Datensatz zu erhalten. Der Datensatz umfasste folgende relevante Parameter:

- Außentemperatur,
- Windrichtung,
- Windgeschwindigkeit,
- Relative Feuchte,
- Niederschlag,
- Strahlung,
- Luftdruck.

Der historische Wärmebedarf wurde aus der Leittechnik der Versorgungsanlage ausgelesen. Durch Abgleich mit den Wetterdaten wurden jeweils fehlende Bereiche entfernt und ein vollständiger Satz von Input- und Outputdaten generiert.

1 Monatlicher und jährlicher Wärmebedarf



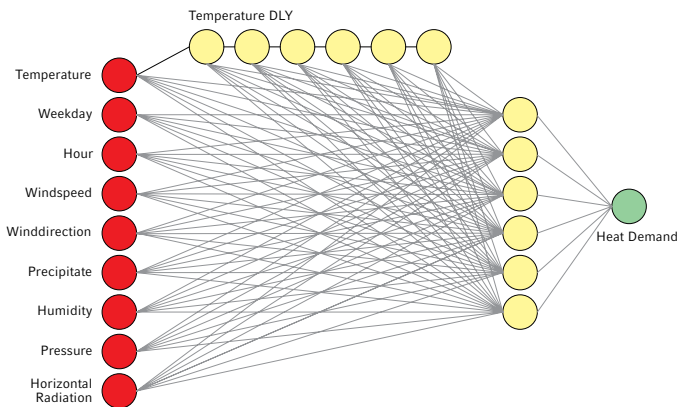
Für die Entwicklung der Wärmebedarfsprognose des Durchschnittsjahres (Systematik der Validierung und des Trainings) werden die Jahre 2010 bis 2012 verwendet, da hier darauf Wert gelegt wird, dass der Datensatz ein ganzes Jahr mit allen Jahreszeiten umfasst. Zusätzliche Daten, die bis Oktober 2013 vorliegen, werden als Trainings- und Validierungsdaten in der ersten Designphase des KNN genutzt. So kann sichergestellt werden, dass die Netztopologie mit einem unabhängigen Datensatz bewertet wird und für die folgenden Schritte keine Bevorzugung oder Verzerrung durch eine doppelte Nutzung von Trainingsdatensätzen stattfindet.

Explizite nutzungsabhängige Faktoren wie die Heizungsregelung oder Belegungspläne werden nicht explizit als Input berücksichtigt, da diese, sofern sie eine zeitliche Regelmäßigkeit besitzen, eng mit der dazugehörigen Uhrzeit korrelieren. Die Methode soll es ermöglichen, eine Wärmebedarfsprognose auch ohne detaillierte Kenntnis über

Verbraucher und Nutzungsrandbedingungen zu erstellen.

Es muss aber sichergestellt werden, dass die Nutzungsstruktur sich über die Periode, von der Daten vorliegen, nicht wesentlich ändert und dass keine Anomalien oder Ausreißer im Wärmebedarf auftreten. Dazu wurde für den monatlichen Wärmebedarf eine Witterungsbereinigung nach VDI 3807 durchgeführt: Es wird ein erhöhter Bedarf im Februar 2012 deutlich, der sich auch im weiteren Verlauf nicht erklären ließ und somit im Datensatz beibehalten wurde. Es sollte dabei erwähnt werden, dass die statischen Verfahren der Witterungsbereinigung lediglich die Temperaturunterschiede berücksichtigen. Die monatlichen Wärmebedarfe sind in Bild 1 dargestellt. Markiert sind der erhöhte Wärmebedarf im Februar 2012 und die beiden Monate, in denen Daten fehlen, die somit in den jeweiligen Monatswerten und der Jahressumme fehlen. Es ist im Vergleich der Jahre keine systematische Veränderung des Wärmebedarfs zu erkennen.

2 Topologie eines KNN



Künstliche neuronale Netze mit sechs Hidden-Units und sechs Zeitverzögerungsneuronen: 6 HD-6 DLY

Bewertungskriterien

Im Rahmen der Methodenentwicklung ist es notwendig, unterschiedliche Netze mit auch teils deutlich unterschiedlichen Inputs zu vergleichen und bzgl. ihrer Prognosegüte zu bewerten.

Als Bewertungskriterien werden einerseits die Gesamtsumme des prognostizierten Wärmebedarfs im Vergleich zum tatsächlichen Wärmebedarf in [%] für die Validierungsperiode, andererseits die mittlere quadratische Abweichung zum tatsächlichen Bedarf in der Validierungsperiode herangezogen. Letzteres Kriterium dient als Maß für die Übereinstimmung der Lastspitzen, da auf Grund des quadratischen Zusammenhangs hier große Abweichungen einen stärkeren Einfluss haben. Es werden nur Netze, die in beiden Kriterien gut abschneiden, weiter betrachtet.

KNN-Design

Es wurden unterschiedliche Inputs, Topologien und Verknüpfungsvarianten ausprobiert, um möglichst gute Netze

für die Wärmebedarfsprognose zu identifizieren. Es gibt keine allgemein gültigen Regeln zum Aufbau von KNN, weswegen hier durch punktuelle Variation von vielversprechenden Topologien einige möglichst gute KNN für die folgenden Untersuchungsschritte identifiziert wurden. Die Tagesstunde wurde in den anfänglichen Versuchen in 24-h-Form als Input hinzugefügt. Ein KNN funktioniert mutmaßlich aber am besten, wenn es die physikalische Realität möglichst gut abbildet bzw. die Form der Inputparameter die Zusammenhänge möglichst genau wiedergibt. Wenn nun also die Stunde 24 und die Stunde 1 betrachtet werden, ist der mathematische Unterschied für das Neuron maximal, der physikalische Unterschied ist jedoch gering, da die Stunden aufeinander folgen.

Mit diesem Grundgedanken wurde eine Transformation der Inputs mittels Sinus- und Cosinus-Funktionen vorgenommen. Die Netze mit Transformation der Tagesstunde zeigten eine Verbesserung,

eine Transformation des Wochentags dagegen eine deutliche Verschlechterung. Darüber hinaus wurden unterschiedliche Ansätze verfolgt, geeignete KNN für die Problemstellung zu entwickeln. Neben der Variation der Anzahl und Anordnung in Ebenen der Hidden-Units (HD) wurden Elemente integriert, die eine Zeitverzögerung (DLY) und ggf. Dämpfung (DCY) des entsprechenden Signals bewirken. Somit ist das neuronale Netz in der Lage, zeitliche Abhängigkeiten von Eingaben zu verarbeiten. Andere Ansätze, die verfolgt wurden, beinhalteten die Rückkopplung des Outputs in das Netz und die Erweiterung der Input-Ebene um die Mittelwerte der Inputparameter (jeweils der letzte Tag, die letzten beiden Tage, die letzte Woche und der letzte Monat). Anhand der genannten Kriterien wurden drei vielversprechende Topologien ausgewählt. Die Netze „6 HD-6 DLY“, „6 HD-12 DLY“ und „6 HD-6 DLY“ Mittelwerte d-2d-w-m erweisen sich als geeignet für die weiteren Untersuchungen. Dabei bezieht sich die erste Zahl auf die Anzahl der Hidden-Units in der Zwischenebene, die zweite auf die Anzahl von Zeitverzögerungsneuronen bezogen auf den Temperatur-Input und die Mittelwerte ebenfalls bezogen auf den Temperatur-Input. Das KNN „6 HD-6 DLY“ ist in Bild 2 dargestellt.

Es konnte mittels Sensitivitätsanalyse nicht ohne weiteres ein Mindestdatensatz an Input-Parametern abgeleitet werden. Die Gewichtung der Kanten eines Neurons liefert lediglich eine Abschätzung, welche Input-Neuronen wie wichtig sind. Die Untersuchungen zur Sensitivität legen jedoch nahe, dass mehr Wetterparameter nicht zu einer Verschlechterung führen, sondern der Einfluss der Parameter über die Gewichtung der Kanten durch das Training berücksichtigt wird. Eine Vorausbauwahl aufgrund von physikalischen Zusammenhängen und Korrelationen ist jedoch generell sinnvoll. Eine Reduzierung der Wetterparameter wäre also lediglich aus Sicht der Handhabung oder bei einem kleinen Datensatz zu empfehlen.

Der Beitrag wird in der tab 2/2016 fortgesetzt.