

Zeitschrift: bulletin.ch / Electrosuisse

Herausgeber: Electrosuisse

Band: 101 (2010)

Heft: 4

Artikel: Lastprognosen im Verteilnetz

Autor: Kronig, Patrick / Höckel, Michael

DOI: <https://doi.org/10.5169/seals-856065>

Nutzungsbedingungen

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften auf E-Periodica. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. Das Veröffentlichen von Bildern in Print- und Online-Publikationen sowie auf Social Media-Kanälen oder Webseiten ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. [Mehr erfahren](#)

Conditions d'utilisation

L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. La reproduction d'images dans des publications imprimées ou en ligne ainsi que sur des canaux de médias sociaux ou des sites web n'est autorisée qu'avec l'accord préalable des détenteurs des droits. [En savoir plus](#)

Terms of use

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. Publishing images in print and online publications, as well as on social media channels or websites, is only permitted with the prior consent of the rights holders. [Find out more](#)

Download PDF: 11.01.2026

ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>

Lastprognosen im Verteilnetz

Traditionelle und neue Methoden zur Vorhersage der Netzlast

Die Öffnung des Schweizerischen Strommarkts brachte transparente Regeln zur Verrechnung der Ausgleichsenergie durch die Swissgrid an die Bilanzgruppenverantwortlichen mit sich. Die Differenz zwischen Fahrplansumme aller Bilanzgruppen-Typen (Soll) und Messdaten (Ist) kann nun erhebliche Kosten verursachen. Gute Lastprognosen werden also immer wichtiger. Die zur Berechnung verwendete Prognose der Netzlast kann auf unterschiedliche Weise ermittelt werden. Aber welche Methoden liefern zuverlässige Daten?

Patrick Kronig, Michael Höckel

Die aus dem Produkt aus der Saldozeitreihe und den Ausgleichsenergielpreisen resultierende Geldmenge wird dem Bilanzgruppenverantwortlichen als Ausgleichsenergie in Rechnung gestellt.

Da die Bilanzgruppenverantwortlichen wiederum die Kosten an jeden Lieferanten weitergeben, ist die Prognose der Netzlast eine gut quantifizierbare wirtschaftliche Herausforderung für jeden Vertrieb geworden.

Lastprognosen liegen sowohl den vorgeschriebenen 1/4-h-scharfen Day-ahead-Fahrplanmeldungen der Energielogistik als auch den 1/4-h-scharfen Einkaufstranchen der Energiebeschaffung zugrunde. Die Fähigkeit zu Erstellung und Management qualitativ hochwertiger Lastpro-

gnosen (lang-, mittel- und kurzfristig für Einzlkunden und Kundengruppen) wird zu einem differenzierenden Faktor im Vertrieb.

Bei der Zuordnung der Preise werden die Über- bzw. Unterdeckung einer Bilanzgruppe und die «systemstabilisierende» bzw. «systemdestabilisierende» Wirkung auf die Regelzone berücksichtigt. Überdeckte Abrechnungseinheiten erhalten hierbei eine Gutschrift, unterdeckte Abrechnungseinheiten erhalten eine Rechnung.

Der Artikel beschreibt traditionelle und neu entwickelte Methoden zur Vorhersage der Netzlast. Es werden die wichtigsten Einflussfaktoren und Prognosemethoden zur Elektrizitätsnach-

frage erläutert und verglichen, und es wird gezeigt, wie man eine einfache Lastprognose mittels Excel/MatLab erstellen kann.

Einflussfaktoren auf die Netzlast

Der Verlauf der elektrischen Lastnachfrage über einen Tag ist von vielen Faktoren abhängig. Für die Güte der Lastprognose ist es wichtig, dass alle relevanten Einflussgrößen qualitativ und quantitativ richtig erfasst werden. Am Beispiel kühler Jahreszeiten wird deutlich, dass niedrige Temperaturen und schlechte Lichtverhältnisse in bestimmten Branchen und Bereichen zu erhöhten Lastgängen durch Heizung und Beleuchtung führen können.

Die Temperatur (z. B. bei Haushaltskunden) spielt bei der Lastprognose eine übergeordnete Rolle. Dabei bewirkt eine tiefe Temperatur eine Erhöhung der Netzabgabe, vor allem durch die zusätzliche Heizlast. Dieser Effekt verschwindet aber in einem Temperaturbereich von ungefähr 10–14°C, sodass man sagen kann, dass ab ungefähr 15°C aufwärts die Netzabgabe unabhängig von der gemessenen Temperatur ist. Eine Erhöhung der Netzlast bei sehr hohen Temperaturen kann durch zusätzliche Kühllast erklärt werden. Ein weiterer, bei passiver und aktiver Sonnenenergienutzung wichtiger Einflussfaktor ist die Globalstrahlung. Sie wirkt sich hauptsächlich über eine Erhöhung der Netzabgabe bei geringer Strahlung, das heißt z. B. bei dichter Bewölkung oder Nebel, durch zusätzliche Lichtlast aus. Die Strahlung wird in W/m² angegeben und wird von diversen Meteoserven in stündlichen Werten angeboten.

Die weiteren Einflussfaktoren sind in **Tabelle I** zusammengefasst. Hierbei wurde ihre Relevanz in Bezug auf den Prognosehlerizont beurteilt.

- Kurzfristprognose: ≤ 10 Tage
- Mittelfristprognose: ≤ 1 Jahr
- Langfristprognose: > 1 Jahr

Klimadaten

Wetterstationen gibt es für verschiedene Aufgaben und Einsatzgebiete. Sie unterscheiden sich nicht nur im Aufbau, der Anzahl und der Art der erfassten

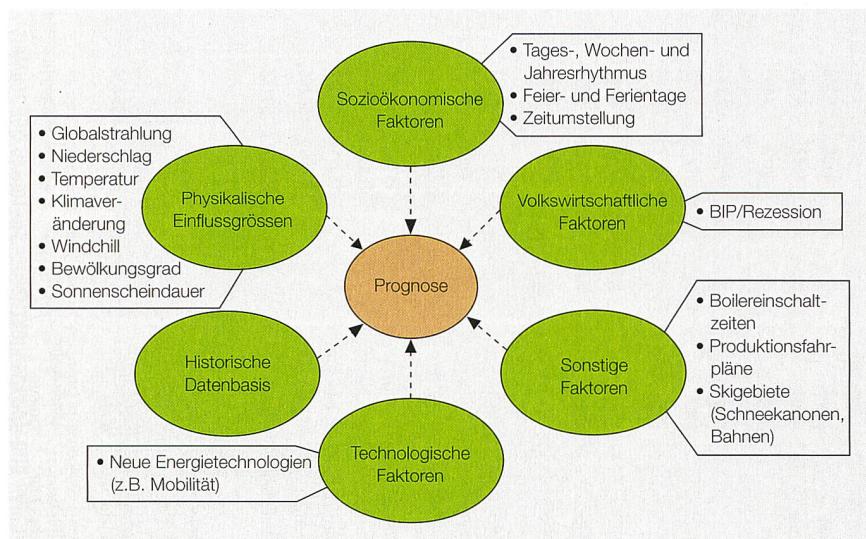


Bild 1 Gruppierung der Einflussgrößen auf die Netzlast.

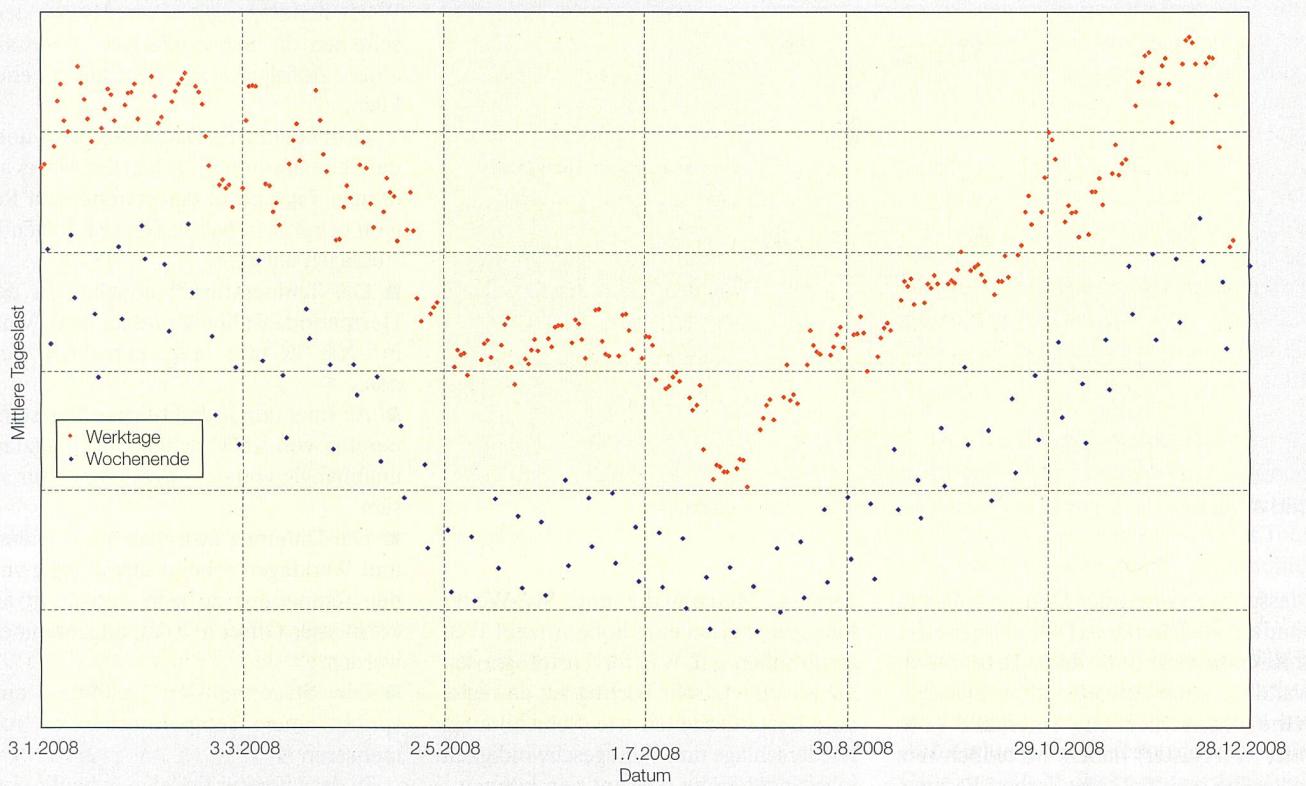


Bild 2 Mittlere Gesamtlast in Abhängigkeit des Datums an Wochenend- (blau) und Werktagen (rot).

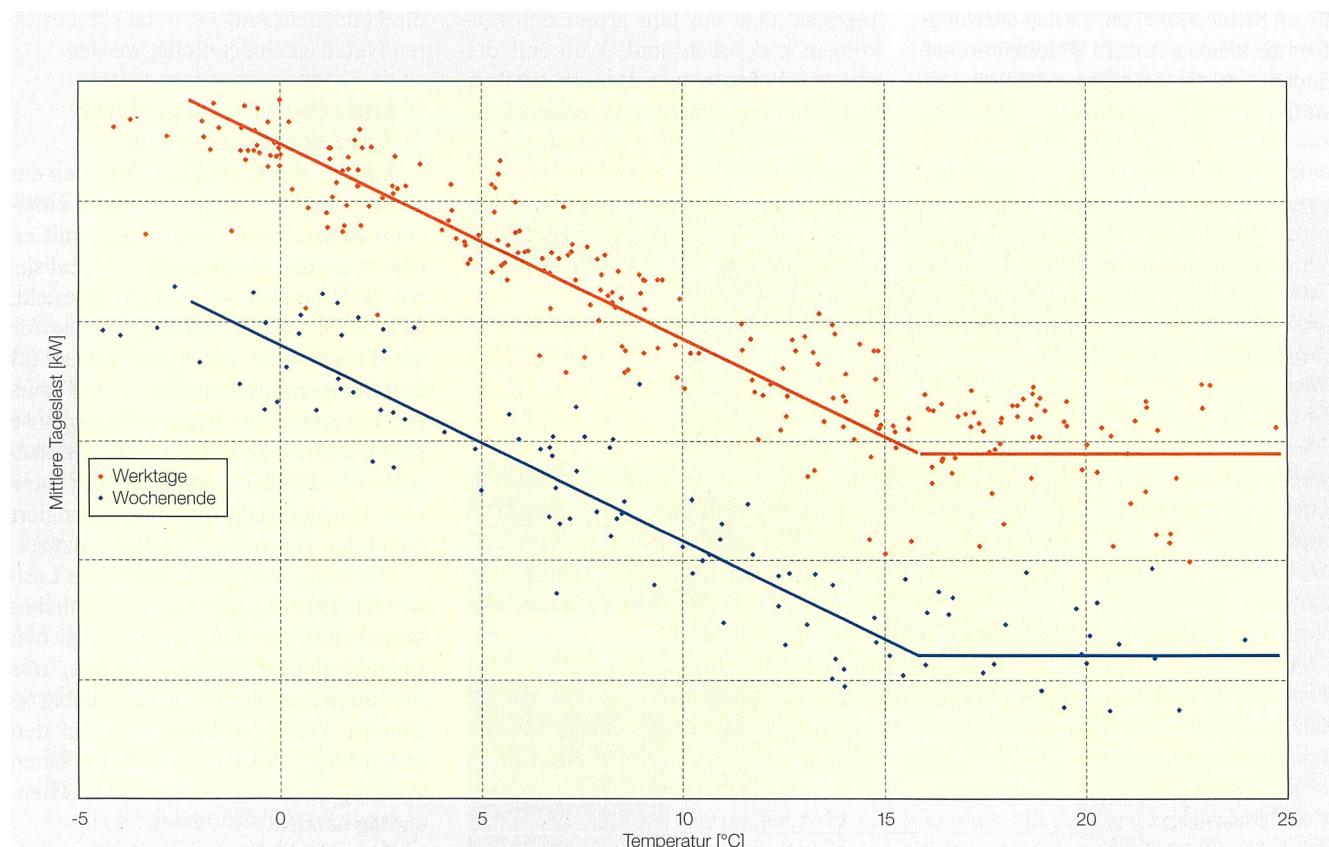


Bild 3 Mittlere Gesamtlast in Abhängigkeit der Temperatur an Wochenend- (blau) und Werktagen (rot) mit eingezeichneter Trendlinie.

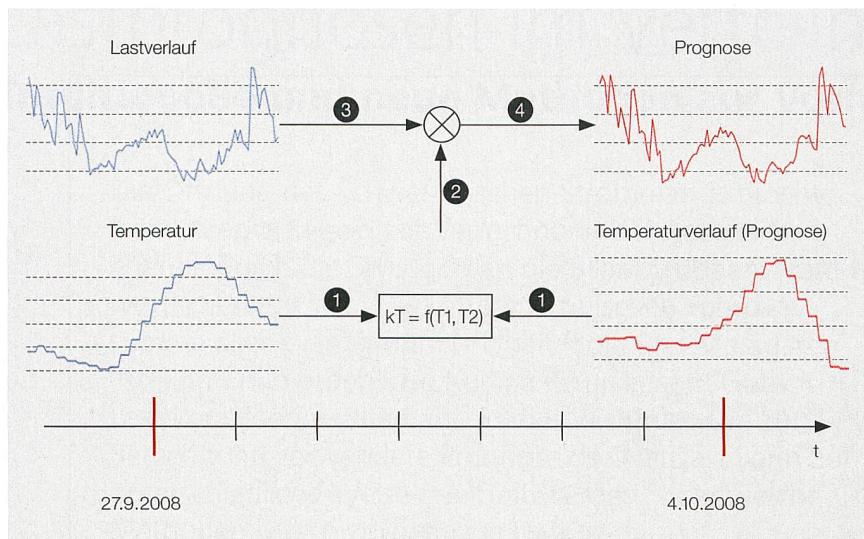


Bild 4 Vorgehen bei der einfachen Lastprognose mit Temperaturkorrektur.

Messgrössen sowie der Messgenauigkeit, sondern auch in der Art der Ausgabe der Informationen und dem Betriebsaufwand. Je nach Anbieter kann die Zeitreihe unterschiedliche Intervalle (1-h- oder $\frac{1}{4}$ -h-Raster) haben. MeteoSchweiz bietet die meisten klimatischen Parameter (Lufttemperatur, Niederschlag, Windgeschwindigkeit und Windrichtung, Luftdruck, relative Luftfeuchtigkeit, Dampfdruck, Globalstrahlung, Sonnenscheindauer, Schneehöhe) an, verfügt allerdings über die kleinste Anzahl Wetterstationen. Zudem sind gemäss eigener Angaben die Stationen bereits baulich und technisch

veraltet. Meteodata und MC-Wetter hingegen weisen eine hohe Anzahl Wetterstationen auf, was für Lastprognosen im Verteilnetz sehr wichtig ist, da regionale Besonderheiten wie Nebelbildung, Niederschläge und Windgeschwindigkeit in geringer Höhe relevant sein können.

Analysen der Netzdaten

Bei der Analyse von Lastdaten wird deutlich, dass im zeitlichen Verlauf der Tageslast über ein Jahr grosse Schwankungen ersichtlich sind. Während der klimatisch bedingte saisonale Einfluss deutlich hervorsticht und wesentliche

sozioökonomische Faktoren, wie beispielsweise die Ferienzeiten und die Wochenendtage, gut erkennbar werden, scheinen die Schwankungen innerhalb einer Abfolge von Werktagen eher klein.

Ordnet man die Daten allerdings über der Temperatur auf, welche im Mittel an diesem Tag und in der betreffenden Region geherrscht hat, lassen sich folgende Aussagen ableiten:

- Die Temperaturabhängigkeit in der Heizperiode ist linear und kann als Wert in $-X\%/{^\circ}\text{C}$ und MW_p berechnet werden.
- Ab einer durchschnittlichen Tagestemperatur von 15°C scheint die Netzlaut unabhängig von der Tagestemperatur zu sein.
- Die Differenz zwischen Wochenend- und Werktagen scheint unabhängig von der Temperatur zu sein und kann als konstanter Offset in MW_p angenommen werden.
- Die Streuung der Lastdaten entspricht einem Temperaturbereich von mehreren K.

In der Literatur findet man häufig eine steigende Last durch zusätzliche Kühllast im Sommer, wodurch ab einer Temperatur von 20°C ein positiver Korrelationskoeffizient auftreten kann. Dies kann direkt mit dem Anteil der voll klimatisierten Nutzflächen begründet werden.

Einfache Prognose durch Temperaturkorrektur

Mithilfe der Korrelationsfaktoren der Temperatur lässt sich mit einem einfachen Ansatz eine Lastprognose mit einem normalen Spreadsheet-Tool realisieren. Das Vorgehen ist in Bild 3 dargestellt. Man sucht sich einen Referenztag für den Prognosetag aus, stellt die Last- (3) und Temperaturdaten (4) für den Referenztag sowie die Temperaturprognose (1) für den Prognosetag zusammen. Anschliessend bildet man einen oder mehrere Korrekturfaktoren und korrigiert damit den Lastverlauf des Referenztags.

Die realen und prognostizierten Lastverläufe (Bild 4) zeigen ein sehr ähnliches Verhalten auf, da nur mit einem täglichen Korrekturfaktor gerechnet wurde. Das Verfahren lässt sich natürlich beliebig erweitern. Der Fachmann sieht auf den ersten Blick, dass es sich nicht um einen Werktag, sondern um einen Wochenendtag handelt.

Die Abweichungen zwischen Prognose und effektiver Last erscheinen gering. Als Gradmesser für die Abweichung

Einflussgröße	Prognosehorizont		
	Kurzfristprognose	Mittelfristprognose	Langfristprognose
Temperatur			
Globalstrahlung			
Niederschlag			
Wind			
Sonnenscheindauer			
Effektive Bewölkung			
Wochentag			
Feier- und Ferientage			
Brückentage			
Weihnachten und Neujahr			
Jahreszeiten (Saison)			
Boilereinschaltzeiten			
Skigebiete			
Produktionsfahrpläne			
BIP/Rezession			
Energiepreise			
Klimaveränderung			
Neue Technologien			
Politik			

Tabelle 1 Einflussfaktoren auf die Elektrizitätsnachfrage und ihre Relevanz (dunkel: stark, hell: schwach, weiß: kein Einfluss) gemäss Einschätzung des Projektteams.

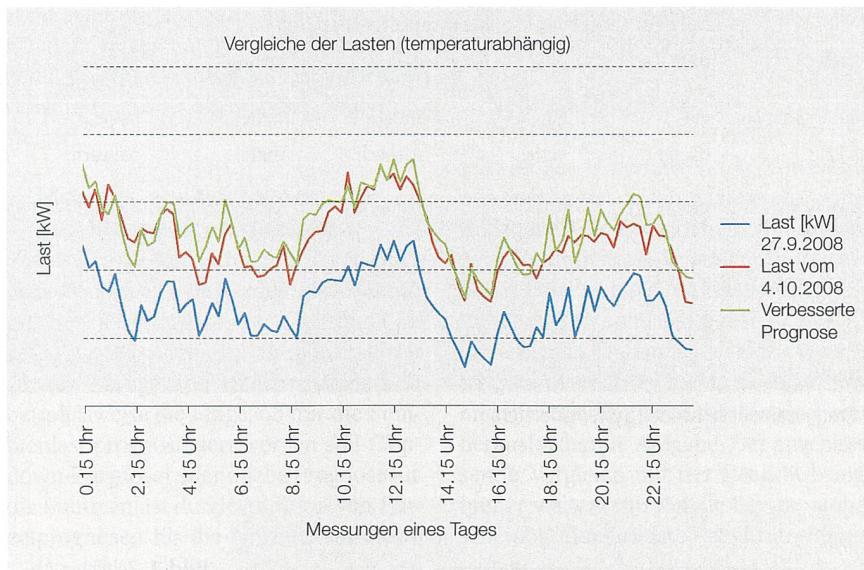


Bild 5 Lastprognose mittels Temperaturkorrektur eines Referenztags.

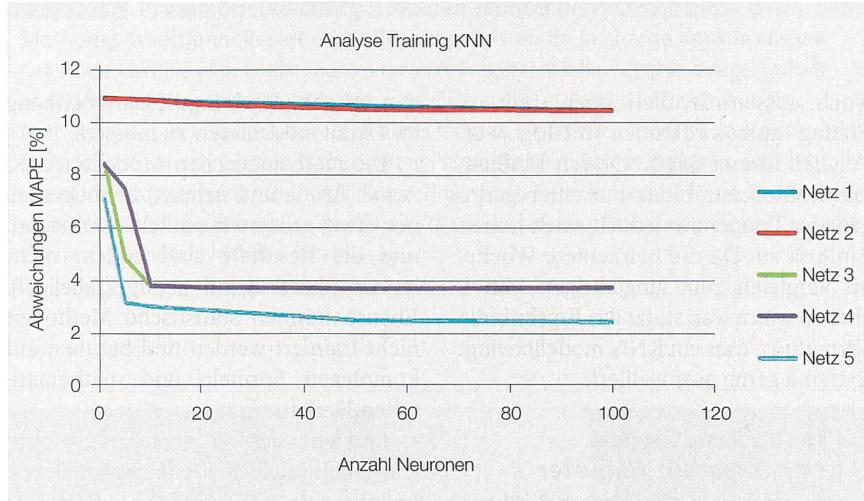


Bild 6 Prognosegüte MAPE in Abhängigkeit von der Anzahl Neuronen und der Inputfaktoren.

zwischen berechneten Modellen und effektiv registrierten Werten wird gerne der MAPE-Index verwendet. Es handelt sich dabei um die absolute prozentuale Abweichung zwischen Prognose und Realität (Mean Absolute Percentage Error):

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \frac{|PRO_i - IST_i|}{|IST_i|}$$

Für dieses einfache Beispiel liegt der MAPE bei 2%, was für eine Lastprognose doch als relativ guter Wert bezeichnet werden kann.

Entwicklung eines KNN in MatLab

Da die Korrelationsfaktoren zwischen den einzelnen Einflussfaktoren auf die Netzlast mathematisch nur sehr schwierig beschrieben werden können, bietet

sich für die Lastprognose die Methode der künstlichen neuronalen Netze (KNN) an. KNN sind in der Lage, eine Größe zu prognostizieren, welche durch eine Vielzahl äußerer Einflüsse bestimmt wird, ohne dass die Abhängigkeiten transparent sein müssen. Allerdings ist es notwendig, über eine grosse historische Datenbasis zu verfügen. Sind die Wirkungen der Einflussgrößen bekannt, kann aus den für die Zukunft angenommenen Werten dieser Einflussgrößen auf die zukünftigen Lastwerte geschlossen werden. Allerdings ist es nicht möglich, dem Tool eine Begründung für sein Verhalten herauszulocken (Black Box).

Ein künstliches neuronales Netz lernt in der Trainingsphase die Abhängigkeit, z.B. einen Lastverlauf von ausgewählten Einflussgrößen, indem Vergan-

genheitswerte dieser Last und Werte der Einflussgrößen desselben Zeitraums einander gegenübergestellt werden. Resultat dieses KNN-Trainings sind Gewichtungsfaktoren, mit denen zukünftige Werte der Einflussgrößen multipliziert werden, um zukünftige Lastwerte zu prognostizieren.

Aufgrund eines integrierenden Verhaltens werden unregelmäßig auftretende Spitzen, die sich mit keinem bekannten Einfluss erklären lassen, durch künstliche neuronale Netze gedämpft. Dies ist als Nachteil zu werten, wenn die Einflussparameter auf die Last stark schwanken bzw. springen.

Die Handhabung eines KNN ist für den Benutzer relativ einfach, wenn man davon ausgeht, dass er ein kommerzielles KNN-Tool, wie es beispielsweise als Toolbox im Softwarepaket MatLab/Simulink angeboten wird, benutzt. Für ein bestehendes Problem ist eigentlich nur festzulegen, mit wie vielen Neuronen (**Bild 5**) das KNN arbeiten soll. Die Hauptarbeit des Programmierers ist die Auswahl und Aufbereitung der Referenzdaten, da die Güte des KNN direkt proportional mit den verfügbaren Datensätzen ansteigt, mit welchen das KNN das Problem kennlernt, also trainiert werden muss.

Im Rahmen der Untersuchungen wurden vielschichtige Versuche gemacht, um herauszufinden, wodurch man eine hohe Prognosegüte erreicht. Zwei sehr anschaulich darstellbare Faktoren sind die Berücksichtigung von Inputfaktoren und die Anzahl von Neuronen, mit welchen das KNN rechnen soll.

In Bezug auf die Inputfaktoren wurden folgende 5 Netze definiert:

- Netz 1: Temperatur.
- Netz 2: Temperatur, Globalstrahlung.
- Netz 3: Temperatur, Globalstrahlung, Wochentage.
- Netz 4: Temperatur, Globalstrahlung, Wochentage, Monate.
- Netz 5: Temperatur, Globalstrahlung, Wochentage, Monate, Kalenderwoche, Ferien.

Natürlich ist zu erwarten, dass mit steigender Anzahl an Inputfaktoren und Knoten die Prognosegüte zunehmen sollte. Allerdings steigt dadurch der Rechenaufwand und die Datenmenge.

Stellt man nun den MAPE in Abhängigkeit dieser Freiheitsgrade dar (**Bild 6**), sieht man relativ schnell, worauf es kommt. Mit der Temperatur als Einflussfaktor erhält man ein MAPE von rund 10,6%. Die Globalstrahlung bringt dabei nur eine geringe Verbesserung. Eine deut-

Kriterien	Modelle zur Lastprognose aus Internetrecherchen						
	Fuzzy	KNN	ALN	ARX	Arma	Arima	Ar(i)x Ar(i)max
Qualität der Versuche (Resultate)	gut bis sehr gut	gut bis sehr gut	gut	gut	mittel	mittel	mittel
Marktdurchdringung (wie viel eingesetzt)	mittelhäufig	häufig	häufig	mittel	schwach	mittel	schwach
Systemanbieter	Kisters AG EnDaNet ProCom DACHS	Kisters AG EnDaNet ProCom Girsberger SAE-IT GIGA Energy DACHS	Kisters AG		Kisters AG	Kisters AG	Kisters AG

Tabelle II Überblick über den Einsatz verschiedener Prognosemodelle bei den Systemanbietern.

liche Verminderung (ca. 6,5 %) des MAPE bringt der Einbezug der Wochentage (Montag bis Sonntag, Feier- und Brückentage). Wie auch der Einfluss der Globalstrahlung führt der Einfluss der Monate (1–12, Januar bis Dezember) zu keiner Verbesserung des Netzes. Unter Berücksichtigung der Kalenderwochen (1–52) und der Ferien lässt sich nochmals eine Verbesserung des MAPE verzeichnen. Zudem ist es ausreichend, mit 15 Neuronen zu arbeiten. Der Gewinn an Genauigkeit ist wohl nur von mathematischer Bedeutung.

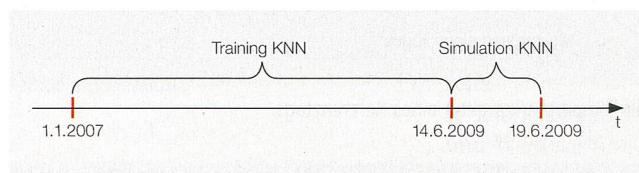
Als Grundlage für die Analysen dienten die Tageswerte von 3 Jahren (2005–2008), also rund 1000 Datensätze.

Testverfahren

Um einen Vergleich mit den aktuellen Prognosen durchzuführen, wurde das Netz mit Daten von 2009 trainiert. Der Zeitraum der historischen Werte ist die Zeitperiode vom 1. Januar 2007 bis zum 14. Juni 2009.

Die Prognose wurde anschliessend mit Daten gemacht, die nicht in der trainierten Netzstruktur vorhanden sind. Bei den Tagen handelt es sich um aufeinanderfolgende Werkstage, an welchen sowohl die mittlere Temperatur als auch die Globalstrahlung recht unterschiedlich waren und welche sich direkt an die historischen Daten des trainierten Netzes anschliessen. Dies würde einem scharfen Einsatz des Tools entsprechen.

Das Ergebnis der zu prognostizierenden Tage (**Bild 8**) zeigt, dass der MAPE bei allen Tagen unter 3% lag. Die Tagesmittellast am Mittwoch wurde auf 1,5% genau prognostiziert, und für den Freitag wurde die Netzlast sogar noch genauer prognostiziert. Interessant ist dabei, dass der Mittwoch etwas wärmer und der Freitag wesentlich kälter als der Rest der Tage, aber die Globalstrahlung am Mitt-

**Bild 7** Zeitlicher Ablauf von Training und Simulation bzw. Prognose.

woch ausserordentlich hoch und am Freitag ausserordentlich niedrig war. Folglich ordnet das KNN den Einflussfaktor Globalstrahlung nur einen geringen, der Temperatur jedoch einen hohen Einfluss zu. Da die betrachtete Woche, im Vergleich zum langjährigen Mittel, eher zu warm war, stützt das Ergebnis die Vermutung, dass ein KNN modellbedingt Extrema gerne ausnivelliert.

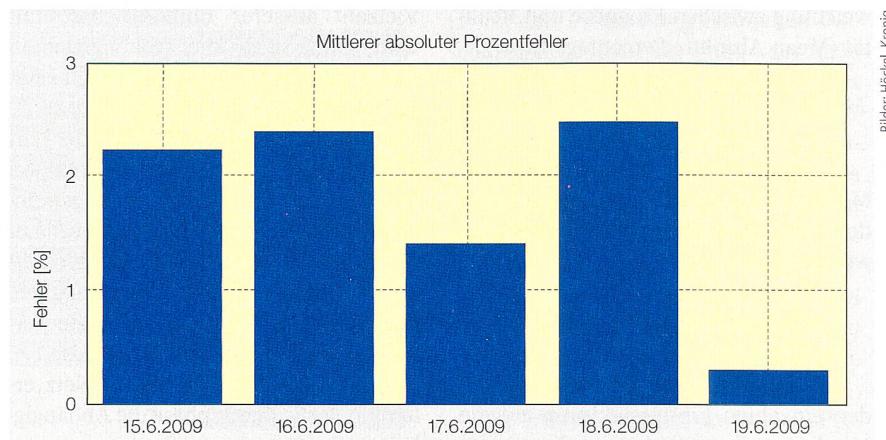
Prognosemethoden kommerzieller Anbieter

Aus den Internetrecherchen wird eindeutig ersichtlich, dass in Zukunft neben Zeitreihenextrapolationsverfahren und kausalen Methoden vermehrt mit künstlichen neuronalen Netzen gearbeitet wird. Mit diesen Systemen können Einflussgrössen berücksichtigt werden, ohne

den Ursache-Wirkungs-Zusammenhang im Detail modellieren zu müssen.

Die mathematischen Modelle (ARX, Arma, Arima und Arimax) benötigen einen etwas grösseren zeitlichen Aufwand, und die Resultate sind zudem nicht immer überzeugend genug (**Tabelle II**). Ebenso können statistische Methoden nicht trainiert werden und beruhen auf komplexen Formeln und mathematischen Herleitungen.

Es bietet sich an, verschiedene Prognosetools intelligent miteinander zu verknüpfen, um ein optimales Ergebnis zu erzielen. Beispielsweise kann in einem nächsten Schritt, das Ergebnis des KNN mittels einer Transferfunktion derart kombiniert werden, dass den relevanten Inputparametern mehr Gewicht zugeordnet wird.

**Bild 8** Prognosegüte MAPE an 5 aufeinanderfolgenden Werktagen im Sommer.

Mit dem Erfolg von künstlichen neuronalen Netzen nahm und nimmt gleichzeitig ihre Verbreitung zu. Die Anforderungen an die Erfahrung des Analysten steigen.

Modelle zur Lastprognose aus Internetrecherchen

Lastprognosen können auf verschiedene Weisen erstellt werden. Wo es nicht nur um die Prognose von Einzelkunden geht, sondern um die Prognose einer ganzen Menge von Kunden, stellt sich beispielsweise die Frage, ob nur die Summenlast prognostiziert werden soll (Top-down-Prognose) oder ob die Prognose für die Summenlast durch Addition von Einzelprognosen für die einzelnen Kunden

oder für einzelne Kundentypen ermittelt werden soll (Bottom-up-Prognose).

Schlussfolgerungen

Die Prognose der Netzlast ist ein schwieriges Unterfangen, da Korrelationen wichtiger Einflussfaktoren wenig transparent und zusätzlich stochastisch verteilte Einflüsse vorhanden sind. Somit bleibt, auch wenn mathematisch hochstehende Tools vorhanden sind und ein umfassendes Datenmaterial zur Auswertung zur Verfügung steht, die kurz- und mittelfristige Prognose der Netzlast eine herausfordernde Aufgabe. Der anschließende Vergleich mit der Realität bringt immer weitere Puzzleteile hervor, wobei scheinbar das gesamte Puzzle aus immer

feineren und kleineren Teilen zu bestehen scheint.

Der vorliegende Artikel ist eine kurze und auf wenige Aspekte fokussierte Zusammenfassung der Inhalte und Ergebnisse eines durch das BFE geförderten Projekts, welches durch zwei umfangreiche Berichte dokumentiert wurde [1, 2].

Referenzen

- [1] Patrick Kronig, Prof. Michael Höckel, Urs Wälchli, Stefanie Zürcher: «ELBE – Validierung und Verbesserung von Lastprognosen (Projektphase 1)»; BFE-Projektbericht Nr. 102771, Oktober 2009.
- [2] Patrick Kronig, Prof. Michael Höckel, Urs Wälchli, Stefanie Zürcher «ELBE – Analyse und Auswertung von Last- und Wetterdaten (Projektphase 2)»; BFE-Projektbericht Nr. 102771, Oktober 2009.

Angaben zu den Autoren

Patrick Kronig hat das Studium an der Berner Fachhochschule 2008 mit dem BSc in Electrical Engineering abgeschlossen. Er hat sich als wissenschaftlicher Mitarbeiter an der BFH-TI Biel u.a. mit Lastprognosen für das Verteilnetz auseinandergesetzt, was ihn zu seinem heutigen Arbeitgeber der BKW FMB Energie AG führte.

BKW FMB Energie AG, 3000 Bern 25,
patrick.kronig@bkw-fmb.ch

Michael Höckel wechselte 1997 von der BKW Energie AG an die heutigen Berner Fachhochschule nach Biel und ist als Professor für Energiesysteme für ein breites Spektrum an Forschungsgebieten von Brennstoffzellen bis Energiewirtschaft verantwortlich.

Berner Fachhochschule – TI, 2501 Biel, hkm1@bfh.ch

Anzeige

Résumé

Prévisions de charge dans le réseau de distribution

Méthodes traditionnelles et nouvelles de prévision de la charge dans le réseau

Cet article identifie et quantifie tous les facteurs importants influençant la charge. La forte corrélation entre la température, la demande d'électricité, et l'activité économique est analysée ainsi que la faible influence d'autres facteurs. A partir des données, deux outils – un procédé basé sur une fonction de transfert et l'autre sur un réseau de neurones artificiel – sont utilisés pour prédire la charge diurne. Finalement, il est démontré à l'aide de divers procédés de test que grâce à ces deux outils, des prévisions de grande fiabilité pour la charge diurne moyenne peuvent être obtenues.



Die Liberalisierung im Strommarkt setzt Impulse frei und eröffnet neue Chancen. Wir verstehen sie als Aufforderung, uns dynamisch weiterzuentwickeln. Dazu sind wir auf engagierte Mitarbeitende angewiesen, wie beispielsweise Tom Frey. Als Key Account Manager findet er flexibel die richtigen Routen zum Erfolg – und trägt so zur Unternehmensentwicklung bei. Bei der BKW-Gruppe sorgen 2800 Mitarbeiterinnen und Mitarbeiter heute dafür, dass bei mehr als einer Million Menschen zuverlässig der Strom fließt. Gehören Sie morgen dazu? Wir freuen uns, wenn Sie mit uns die Zukunft angehen.

BKW FMB Energie AG, Human Resources Management, Telefon 031 330 58 68,
info@bkw-fmb.ch, www.bkw-fmb.ch/karriere

BKW®