

# **Lastprognosen mit neuronalen Netzen : Vorhersage der stündlichen Last bei einem Zeithorizont von bis zu sieben Tagen : ein gemeinsames Projekt von EOS, EPFL und ABB**

Autor(en): **Buchenel, Bernard / Germond, Alain / Piras, Antonio**

Objekttyp: **Article**

Zeitschrift: **Bulletin des Schweizerischen Elektrotechnischen Vereins, des  
Verbandes Schweizerischer Elektrizitätsunternehmen = Bulletin de  
l'Association Suisse des Electriciens, de l'Association des  
Entreprises électriques suisses**

Band (Jahr): **87 (1996)**

Heft 21

PDF erstellt am: **22.07.2024**

Persistenter Link: <https://doi.org/10.5169/seals-902377>

## **Nutzungsbedingungen**

Die ETH-Bibliothek ist Anbieterin der digitalisierten Zeitschriften. Sie besitzt keine Urheberrechte an den Inhalten der Zeitschriften. Die Rechte liegen in der Regel bei den Herausgebern.

Die auf der Plattform e-periodica veröffentlichten Dokumente stehen für nicht-kommerzielle Zwecke in Lehre und Forschung sowie für die private Nutzung frei zur Verfügung. Einzelne Dateien oder Ausdrucke aus diesem Angebot können zusammen mit diesen Nutzungsbedingungen und den korrekten Herkunftsbezeichnungen weitergegeben werden.

Das Veröffentlichen von Bildern in Print- und Online-Publikationen ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. Die systematische Speicherung von Teilen des elektronischen Angebots auf anderen Servern bedarf ebenfalls des schriftlichen Einverständnisses der Rechteinhaber.

## **Haftungsausschluss**

Alle Angaben erfolgen ohne Gewähr für Vollständigkeit oder Richtigkeit. Es wird keine Haftung übernommen für Schäden durch die Verwendung von Informationen aus diesem Online-Angebot oder durch das Fehlen von Informationen. Dies gilt auch für Inhalte Dritter, die über dieses Angebot zugänglich sind.

Planung ist eine der Hauptaufgaben von Energieversorgungsunternehmen (EVU) und die Voraussetzung für eine sichere, wirtschaftliche und ressourcenschonende Energieversorgung. Die Lastvorhersage steht am Anfang jeglicher Planung. Je nach Zielsetzung ist der Zeithorizont unterschiedlich. Im vorliegenden Artikel wird die Vorhersage der stündlichen Last mit dem Zeithorizont von einer Stunde bis zu sieben Tagen diskutiert. In diesem Bereich hängt die Vorhersage hauptsächlich von vergangenen Lastwerten, von Wetterbedingungen, wie zum Beispiel Temperatur, und von verschiedenen zusätzlichen Einflüssen ab.

# Lastprognosen mit neuronalen Netzen

**Vorhersage der stündlichen Last bei einem Zeithorizont von bis zu sieben Tagen - Ein gemeinsames Projekt von EOS, EPFL und ABB**

■ Bernard Buchenel, Alain Germond, Antonio Piras, Yves Jaccard, Karl Imhof, Jakob Bernasconi und Peter Dondi

Bis heute konnte sich für die Lastvorhersage noch kein automatisches Verfahren allgemein durchsetzen. Aus diesem Grund werden Lastprognosen vielerorts durch die Planungsingenieure ohne technische Hilfsmittel erstellt. Moderne Verfahren können unter geeigneten Umständen die Qualität der Vorhersagen von erfahrenen Experten erreichen oder sogar übertreffen. Solche Verfahren sind in der Benutzung nicht kompliziert und sind somit auch nicht personenabhängig. Die Verwendung rechnergestützter Verfahren führt ausserdem zu Vorhersagen nach einheitlichen Kriterien, die zu beliebigen Zeitpunkten erstellt werden können.

Im Artikel wird ein gemeinsames Forschungsprojekt zwischen Electricité Romande, vertreten durch EOS (Energie de l'Ouest-Suisse SA), EPFL-LRE (Ecole Polytechnique Lausanne, Laboratoire des Réseaux d'Énergie Électrique) und ABB Network Partner AG, beschrieben. Ziel war die Entwicklung eines Vorhersagepaketes auf der Basis von neuronalen Netzen. In einem mehrmonatigen Online-Betrieb wurde die Praxistauglichkeit unter Beweis

gestellt. Dabei wurden tägliche Lastvorhersagen für das EOS-Netz und für die einzelnen Partnernetze erstellt und mit den Vorhersagen der Planungsabteilung verglichen.

Der Einsatz von neuronalen Netzen zur Lastvorhersage entspricht dem heutigen Stand der Technik, wie eine grosse Zahl von Publikationen belegt. Ein entscheidender Vorteil dieser Verfahren ist die Lernfähigkeit. Sobald man strukturell die Abhängigkeiten ermittelt hat, ist die Berechnung und die laufende Anpassung des mathematischen Modells heute wesentlich einfacher als früher.

Der Schritt zu einem praxistauglichen Modell ist vielleicht der schwierigste Teil. Die Resultate müssen zuverlässig und genau sein, und ein Prognosewerkzeug muss zu einer echten Entlastung der Planungsingenieure führen. Die Anpassung an die Organisation und Besonderheit des Benützers ist der Teil, der über die praktische Verwendung entscheidet. Im vorliegenden Fall wurden auch diese Hindernisse erfolgreich gemeistert.

## Projektübersicht

Von Frühjahr 1993 bis Sommer 1996 lief ein gemeinsames Forschungsprojekt zwischen EOS, EPFL-LRE und ABB Network Partner. Zusammengefasst bestand folgende Absprache:

### Adressen der Autoren

Prof. Dr. Alain Germond und Antonio Piras  
Laboratoire des Réseaux d'Énergie Électrique (LRE), Ecole Polytechnique Fédérale  
1015 Lausanne

Dr. Yves Jaccard, EOS SA, Pl. de la Gare 12  
1003 Lausanne

Dr. Karl Imhof, Atel AG, Bahnhofquai 12  
4600 Olten (bis Anfang 1996 bei ABB Network Partner für dieses Projekt verantwortlich)

Dr. Jakob Bernasconi, ABB Forschungszentrum  
5405 Baden-Dättwil

Dr. Peter Dondi und Bernard Buchenel  
ABB Network Partner AG, 5300 Turgi



- ABB finanziert eine Assistentenstelle bei EPFL-LRE, liefert Know-how und Erfahrung aus früheren Produkten und Projekten [1] und spezifiziert den Rahmen des Projektes aufgrund von Kundenanforderungen. Die Stelle wurde von einem ABB-Trainee besetzt, der im Laufe eines Jahres ABB als Konzern kennengelernt hatte und dabei persönliche Kontakte zu Leuten von ABB Network Partner aufgebaut hatte.
- LRE entwickelt ein Lastvorhersageprogramm, das auf neuronalen Netzen basiert. LRE besitzt zu diesem Zeitpunkt bereits Erfahrungen auf dem Gebiet der Lastvorhersage mit neuronalen Netzen [2].
- EOS stellt seine praktische Erfahrung und Daten für Offline-Tests zur Verfügung. Ein geeigneter Prototyp sollte später durch die Planungsabteilung getestet und beurteilt werden.

Bereits Ende 1994 stand ein Verfahren zur Verfügung, das erstaunlich gute Resultate lieferte. Das Ergebnis konnte in der Fachpresse publiziert werden [3]. Bei LRE wurde auf der Basis neuronaler Netze mit anderen Modellen weiter geforscht. Bereits existierende Ansätze wurden aufgrund der gewonnenen Erfahrungen weiterentwickelt.

### Entlastung für Planungsingenieure

Auf der Basis dieser Arbeiten wurde der Planungsabteilung von EOS ein Prototyp auf PC-Plattform zur Verfügung gestellt. Dieses Werkzeug erforderte Zusatzaufwand, um optimal zu funktionieren. So mussten zum Beispiel Last- und Wetterwerte konsequent und korrekt eingegeben werden. Das Werkzeug wurde vorerst nicht benutzt; offenbar hatte man vergessen, dass

der Hauptzweck eines Vorhersagepaketes darin besteht, die Planungsingenieure zu entlasten. Deshalb musste nach einer Lösung gesucht werden, die den Zusatzaufwand eliminierte. Mit der im Abschnitt «Test und Ergebnisse – Online-Testumgebung» beschriebenen Implementierung wurde man dieser Situation gerecht.

In einem Testbetrieb wurden zwischen Januar und April 1996 täglich Lastvorhersagen für EOS und Partner erstellt und den verschiedenen Planungsabteilungen zur Verfügung gestellt. Festzuhalten ist, dass die Genauigkeit der Lastvorhersage mit neuronalen Netzen nachgewiesenermaßen besser war als mit der bisherigen Methode. Die Verwendung automatischer Lastvorhersagen erlaubt dem Planungsingenieur, sich auf die eigentlichen Planungsaufgaben zu konzentrieren.

### Die Spezifikation von EOS

Energie de l'Ouest-Suisse SA (EOS) mit Hauptsitz in Lausanne ist zuständig für die Erzeugung und die Übertragung von elektrischer Energie in der Westschweiz (Bild 1). Die wichtigsten Teilhaber an EOS (Partner) sind die Unternehmen Service Electrique de Lausanne (SEL), Services Industriels de Genève (SIG), Compagnie Vaudoise d'Electricité (CVE), Entreprises Electriques Fribourgeoises (EEF), Société Romande d'Electricité (SRE). Die Partner haben eigene Kraftwerke und liefern einen signifikanten Anteil der Produktion. EOS ist zuständig für die Gesamtenergie im Netz und verantwortlich für die Produktionsplanung. Das sind Koordinationsaufgaben zur Steuerung der Produktion. Dazu gehören auch der Einkauf und Verkauf von elektrischer Energie, auf nationaler und internationaler Ebene. Das Versorgungsgebiet von EOS und Partnern




Bild 1 Das Versorgungsgebiet von EOS und Partnern mit 1 Million Einwohnern

umfasst eine Fläche von 5000 km<sup>2</sup>, mit 1 Million Einwohner. Die Lastspitze liegt bei über 1000 MW.

EOS stellt folgende Anforderungen an die Vorhersage der stündlichen Last:

- Angabe von stündlichen, mittleren Verbrauchswerten. Die Verbrauchswerte werden bis auf kleine Störeinflüsse präzise ermittelt und archiviert.
- Stündliche Mittelwerte für die folgenden 48 Stunden, an Wochenenden für die nächsten 96 Stunden.
- Die Vorhersage muss jeden Morgen um 7 Uhr mit den aktuellen Daten erstellt werden und kurz darauf verfügbar sein.
- Die Genauigkeit der Vorhersage soll gegenüber bisherigen Verfahren besser sein.

EOS kann für die Bestimmung des Vorhersagemodelles lückenlose, automatisch archivierte Lastdaten ab Anfang 1993 zur Verfügung stellen.

## Stand der Technik – Problemdefinition

### Was ist Lastvorhersage?

Die kurzfristige Lastvorhersage (Short-term load forecast) liefert stündliche oder halbstündliche Vorhersagen für die Last mit Zeithorizont von 1 bis 168 Stunden (1 Woche). Von Bedeutung ist dies für die Beurteilung der Netzsicherheit für die nächsten Stunden. Die Lastvorhersage liefert somit dem Netzbetreiber Entscheidungsgrundlagen für die tägliche Netzführung. Die kurzfristige Lastvorhersage macht Aussagen betreffend:

- tägliche Lastspitzen
- stündlichen Verlauf der Systemlastenkurve im Laufe des Tages
- stündliche, tageweise oder wöchentliche Energiewerte

Für eine Modellierung sind die folgenden Abhängigkeiten von Bedeutung:

- *Vergangene Lastwerte:* Besonders aussagekräftig sind zum Beispiel die Lastwerte des vorangehenden Tages. Die Systemlast weist ausgeprägte Tages-, Wochen- und Jahreszyklen auf. Feiertage haben dagegen ein besonderes Lastverhalten.
- *Wetterwerte:* In der Regel wird die erwartete Temperatur um den Zeitpunkt der Vorhersage verwendet, andere Wettergrößen sind zum Teil schwer vorhersehbar (z. B. stündliche Regenmengen) und deshalb ungeeignet. Die Verwendung zu vieler Wetterfaktoren wird nicht empfohlen, da diese korreliert sind. Zudem hat das Wetter lokal unterschied-



liche Auswirkungen. Es ist zu beachten, dass das Wetter für sich allein das Lastverhalten nicht beliebig genau erklären kann.

- «*Störgrößen*»: Darunter hat man verschiedene, nicht explizit modellierte Größen zu verstehen, die in jedem EVU anders sein können. Zudem hängt dieser Faktor stark von der gemessenen Größe ab und was darin eingeschlossen ist. Mögliche, schwer vorhersehbare Einflüsse sind zum Beispiel die Auswirkungen von Rundsteuerungen, sofern diese Informationen nicht ins Modell einbezogen werden.

Die Lastvorhersage hat die Aufgabe, geeignete Modelle für diese Abhängigkeiten zu finden und zu verwenden. Eine Reihe von Methoden wurde im Verlauf der Zeit mit mehr oder weniger Erfolg verwendet [4]. Im Bereich der Lastvorhersage hat sich keine eigentliche Standardmethode durchsetzen können – im Gegensatz zu Netzfunktionen wie Zustandsestimation, Ausfallanalyse und andere.

Schwierigkeiten bei der Modellierung können oft durch die geeignete Festlegung der gemessenen und vorhergesagten Größe umgangen werden. Das Vorhandensein eines leistungsfähigen SCADA-Systems (mit korrekter Datenübermittlung und Archivierung) ist von Bedeutung für die Qualität der historischen Lastdaten und somit für die Ergebnisse der Modellierung und der Vorhersage.

Man sieht oft, dass Planungsingenieure mit einer Art Mustererkennung arbeiten. Verwendet und analysiert werden die vorangehenden Tage mit vergleichbaren Bedingungen. Wettervorhersagen sowie eine schwer beschreibbare Menge von tagespezifischen Informationen spielen eine Rolle; die Verarbeitung dieser Informationen ist stark personenabhängig.

### Stand der Technik

Das Lastvorhersageproblem wurde bis heute mit verschiedenen Ansätzen angegangen. Als Beispiele seien erwähnt: lineare Modelle, stochastische Zeitreihenanalyse, General exponential smoothing, Zustandsraum-Methoden und Expertensysteme (vgl. hierzu [1], [4–7]). Keine der Methoden erwies sich jedoch als überlegen in bezug auf die Genauigkeit der Resultate. Neuronale Netze haben die Eigenschaft, dass sie nichtlineare Funktionen mehrerer Variablen nachbilden können. In unserem Fall ist das beispielsweise die Wechselwirkung zwischen elektrischem Verbrauch und Wettervariablen. Ein weiteres Argument für die neuronalen Netze ist die *Lernfähigkeit*, das heisst, es handelt sich um leistungsfähige Estimationsmethoden,

die eine Anpassung an das vergangene Verhalten mit einschliessen. Eine grössere Anzahl Publikationen beschreibt verschiedene Ansätze für die Lösung des Lastvorhersageproblems mit neuronalen Netzen [8].

Das Interesse der Industrie und der EVU zeigt sich dadurch, dass viele Publikationen von Autoren aus Forschung und Industrie gemeinsam verfasst sind. Viele Arbeiten sind theoretischer Natur und die Resultate haben vorerst nur wenig Bedeutung für die Praxis. So beschränken sie sich auf die Vorhersagen an Werktagen oder auf die Vorhersage für die nächste Stunde. In diesen Fällen geht es meistens um die Realisierbarkeit besonderer Methoden für die Lastvorhersage. Für die Anwender von Bedeutung sind die Feldtests, die zusammen mit EVUs unter realistischen Bedingungen ausgeführt wurden; im folgenden seien erwähnt: Pacific Gas & Electric Co. [9, 10], ABB Systems Control [11], EDF [12, 13], Tractebel SA [14], Toshiba Corp. [15], Siemens AG [16], Puget Sound Power & Light [17], Fuji Electric Co. [18], ABB Network Partner AG [3, 19], Epri [20, 21]. Das Ziel dieser Projekte war die Entwicklung kommerziell nutzbarer Werkzeuge für die Lastvorhersage. Diese Produkte sollten mindestens so leistungsfähig sein wie die bereits bestehenden sogenannten klassischen Methoden, aber im Unterhalt wesentlich komfortabler.

### Neuronale Netze

In den letzten Jahren hat sich der Einsatz von künstlichen neuronalen Netzwerken bei der Modellierung und Vorhersage von verschiedenen nichtlinearen Prozessen als sehr vielversprechend erwiesen. Künstliche neuronale Netzwerke imitieren gewisse Prinzipien und Eigenschaften der Informationsverarbeitung in biologischen Nervensystemen [22]. Sie bestehen aus einer Anzahl von sehr einfachen Prozessoren (künstlichen Neuronen), die durch gewichtete Verbindungen interaktiv miteinander verknüpft sind. Die wohl interessanteste Eigenschaft solcher Systeme ist ihre Fähigkeit, durch Anpassung der Verbindungsgewichte eine vorgegebene Aufgabe aufgrund von Beispielen selbständig zu lernen. Neuronale Netzwerke können im Prinzip beliebige nichtlineare Zusammenhänge in einem vorgegebenen Datensatz erkennen und modellieren. Die entsprechenden Lernverfahren sind zudem auch dann sehr effizient, wenn die Beobachtungen verrauscht sind oder sogar widersprüchliche Daten enthalten.

Der Einsatz von neuronalen Netzwerken in Vorhersage-Anwendungen beruht mei-

stens auf einem der folgenden zwei Prinzipien:

- Modellierung von Korrelationen zwischen vergangenem und zukünftigem Verhalten
- Erkennen von charakteristischen zeitlichen Mustern

Für die Modellierung von Korrelationen werden in erster Linie mehrschichtige Feedforward-Netzwerke eingesetzt, die fähig sind, auch sehr nichtlineare Input-Output-Relationen zu approximieren [22]. Die Funktionsweise einer anderen Klasse von neuronalen Netzwerken, die der sogenannten Kohonen-Netzwerke [2], ist speziell darauf zugeschnitten, statistisch signifikante Muster in einer Zeitreihe zu identifizieren und wieder zu erkennen. In beiden Fällen erfolgt das Training der Netzwerke aufgrund von historischen Daten. Bei der Vorhersage von nicht-stationären Prozessen muss dieser Trainingsvorgang periodisch wiederholt werden.

### Bestimmung von geeigneten Modellen

Bei der Modellierung der Last und der Bestimmung der entsprechenden neuronalen Netze sind die folgenden Schritte von Bedeutung. Diese Schritte sind jeweils voneinander abhängig:

- Auswahl und Transformation der Inputvariablen
- mathematische Formulierung der Architektur des neuronalen Netzes
- Lernphase (Parameterestimation)
- Modellauswahl und Validierung

Eine wichtige Aufgabe bei der Modellbildung ist die Auswahl der Inputvariablen – dafür gibt es kein systematisches Verfahren. Das Problem kann jedoch praktisch angegangen werden. Zur Verfügung stehende Variablen müssen schrittweise zum Modell hinzugefügt und gegebenenfalls wieder entfernt werden, bis eine hinreichende Genauigkeit erreicht wird. Ein vergleichbares Vorgehen steht aus der Theorie der linearen Regression zur Verfügung [23]. So wurden folgende Werkzeuge aus der Statistik erfolgreich verwendet: Variablentransformationen, Autokorrelation, partielle Autokorrelation [24] und Kreuzkorrelation zwischen verschiedenen und zeitverschobenen Inputvariablen. Obwohl das Lastverhalten von vielen Faktoren beeinflusst wird, muss man sich auf diejenigen Inputgrößen beschränken, die in ausreichender Genauigkeit zur Verfügung stehen.

Konkret waren das im hier beschriebenen Projekt: sieben Tage zurückliegende gemessene Lastwerte, die Werte der zwei vorangehenden Tage, mittlere Temperatur-



maxima und -minima des vorangehenden Tages, die für den Tag vorhergesagten Temperaturen und als Indikatoren der Wochentag und der Jahrestag.

Es wurde der Ansatz benutzt, die Last- und die Temperaturkurven in drei Komponenten aufzuteilen: Langzeit-, Saisonal- und Residuenkomponente. Die Vorhersage besteht aus der Summe dieser Komponenten.

### Algorithmus für die Lastvorhersage<sup>1</sup>

Die Langzeitkomponente beschreibt den Jahreszuwachs (2-5%). Für den betrachteten Zeithorizont sind die Auswirkungen dieser Komponente bei hiesigen Verhältnissen vernachlässigbar. Estimiert man die Parameter des Gesamtmodells mehrmals pro Jahr, so wird das Langzeitverhalten durch die anderen Komponenten getragen.

Die saisonale Komponente wird modelliert mit multivarianter, linearer Regression unter Verwendung der erwähnten Inputgrößen. Es werden separat Last und Temperatur modelliert. Im Falle der Last werden die folgenden Größen ermittelt:

Wochenmodell:

$$w_h = \sum_{j=0}^6 c_{j,h} \cdot b_j + \epsilon \quad (1)$$

wobei  $h = 1-24$ ,  $b_j$  Tagesindikatoren,  $c_{j,h}$  Parameter,  $W_h$  stündlicher Wert für Wochenstunden,  $\epsilon$  Fehler (normalverteilt) bedeuten. Die 168 Werte  $c_{j,h}$  beschreiben die mittlere Lastkurve einer Woche.

Jahreszeitabhängige Korrektur:

$$y_h = a_{1,h} \cdot \cos\left(2\pi \frac{d}{365}\right) + a_{2,h} \cdot \sin\left(2\pi \frac{d}{365}\right) + \epsilon \quad (2)$$

wobei  $d = 1-365$ ,  $h = 1-24$ ,  $y_h$  die jahreszeitabhängige Korrektur zur Tageszeit  $h$  angibt;  $a_{1,h}$  und  $a_{2,h}$  sind Parameter.

Die Summe des Wochenmodells und der jahreszeitabhängigen Korrektur ergibt die saisonale Komponente. Im Falle der Temperatur ist kein Wochenmodell erforderlich. Die saisonale Komponente ist als neuronales Netz (10-24 Adaline) implementiert.

Die Residuenkomponente wurde mit einem Multi-Input/Multi-Output-Multi-Layer-Perzeptron (Mimo MLP) modelliert, welches als Input die Abweichungen der gemessenen Werte zu den saisonalen Last- und Temperaturmodellen verwendet. Das MLP wird zu Beginn grosszügig dimensioniert.

<sup>1</sup> Aus Platzgründen können in diesem Abschnitt nicht alle Fachausdrücke erläutert werden. Der interessierte Leser sei auf die nachfolgende Literaturliste verwiesen.

Die Berechnung der Parameter (Gewichte) erfolgt mit einem iterativen Verfahren (Back propagation), ausgehend von zufällig verteilten Werten. Die Anzahl der Neuronen wird optimiert unter Verwendung von Regularisierungstechniken. Im Funktional (3) werden die Quadratsumme der Vorhersagefehler sowie die Anzahl und Grösse der Parameter minimiert:

$$\sum_{i=1}^n \{y_i - f(x_i, w)\}^2 + \lambda \Phi\{f(x_i, w)\} = \min \quad (3)$$

wobei  $y_i$  Lastwerte,  $x$  Inputwerte,  $w$  Gewichte (gesuchte Parameter),  $\lambda > 0$  der Regularisierungsfaktor,  $\Phi\{\}$  eine Stabilisierungsfunktion,  $f(\)$  eine Vorhersagefunktion bedeuten.

Um das beste Modell für zukünftige Werte zu finden, werden die vorhandenen historischen Daten in Lern- und in Validierungsdaten aufgeteilt. Das Validierungsset umfasst ungefähr 20% der Gesamtdaten und wird zufällig bestimmt. Während der Estimationsphase (Lernphase) nimmt das Fehlerfunktional auf den Estimationsdaten kontinuierlich ab, während auf den Validierungsdaten das Fehlerfunktional nach einer Anzahl Iterationen wieder grösser wird. In diesem Moment tritt Overfitting ein, das heisst das Modell ist überparametrisiert. Die so erhaltenen Parameter bewirken in der Zukunft bereits ein schlechteres Verhalten des Modells. In diesem Moment muss die Estimationsprozedur abgebrochen werden («early stopping»).

gestellten Anforderungen modelliert. Über das spätere Verhalten unter echten Bedingungen kann noch keine definitive Aussage gemacht werden.

Unterschiede zwischen Echtzeitbetrieb und dem beschriebenen Offline-Testing bestehen in verschiedener Hinsicht. Über den Zeitraum der Archivierung sind in der Regel die genauen Lastwerte und die nachträglich gemessenen Temperaturwerte verfügbar. Der Planungsingenieur (im Online-Betrieb) hat die Lastdaten der letzten Stunden zur Verfügung, die er gegebenenfalls korrigieren muss – was aufgrund seiner Erfahrung ohne Schwierigkeiten möglich ist. Auch bei den Wettervorhersagen muss unter Umständen mit falschen Werten gearbeitet werden. Es besteht somit die Gefahr, dass eine Offline-Simulation von anderen Annahmen ausgeht und für die Praxis keine verlässlichen Anhaltspunkte liefert. Zum Beispiel kann ein Modell zu stark von exakten Wetterangaben abhängen oder sich als zu wenig robust bei fehlerhaften Inputwerten erweisen.

Der Versuch, der Planungsabteilung einen Prototypen auf PC zur Verfügung zu stellen, war im Laufe des Jahres 1995 fehlgeschlagen. Die Bedienung eines nichtintegrierten Forecasting-Pakets ist mit nicht zu unterschätzender Mehrarbeit verbunden. Die Erstellung der Vorhersage nach altem Muster war schneller und einfacher. Sollte ein Online-Test wirklich durchgeführt werden, so musste die Zusatzbelastung der Planungsingenieure eliminiert werden.

Im folgenden wurde ein automatisiertes Verfahren implementiert (Bild 2):

- Ein Batch-Job extrahiert die benötigten Lastdaten aus dem EOS-System und sendet diese per E-Mail zu EPFL-LRE/ABB.
- Bei EPFL-LRE besorgt ein weiterer Batch-Job die Wetterdaten für ausgewählte Wetterstationen (Filetransfer).

## Test und Ergebnisse

### Online-Testumgebung

Zur Beurteilung des gewählten Vorhersageverfahrens sind auf den vorhandenen archivierten Daten vorerst ausgiebige Tests nötig. Das Ergebnis ist ein Verfahren, das die Archivdaten gemäss den

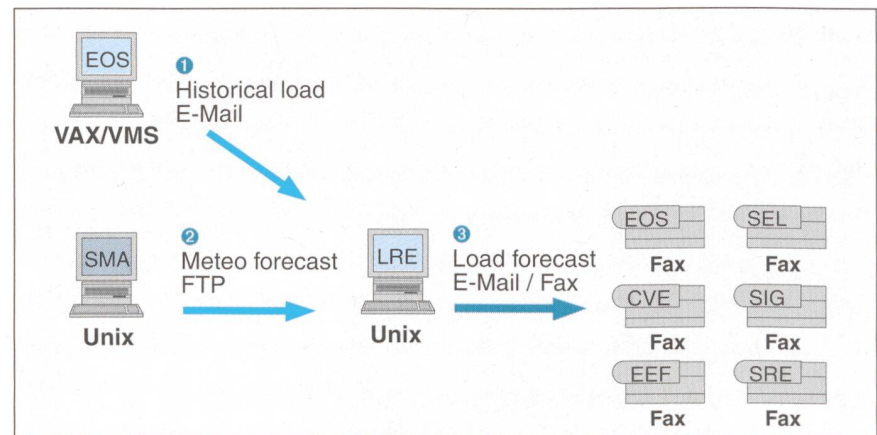


Bild 2 Konfiguration für den automatisierten Testbetrieb






Bild 3 Typischer Lastverlauf und dessen Vorhersage an Werktagen

für den Wochenbeginn waren etwas schlechter, weil diese nicht einen Tag im voraus, sondern bereits am Freitag gemacht werden mussten.

### Schlussfolgerung - Start für neue Projekte

Die Ziele des Projektes sind aus Sicht der beteiligten Projektpartner vollumfänglich erreicht und sogar übertroffen worden. Diese Ziele waren:

- *Entwicklung eines praxistauglichen Lastvorhersagepakets:* Diese Aufgabe war das Thema der Dissertation von A. Piras. Die Arbeit konnte in kurzer Zeit und erfolgreich abgeschlossen werden.
- *Erfahrungsaustausch zwischen EVU, Entwicklern und Hochschule:* Die Art der Zusammenarbeit ging über den Rahmen einer normalen Kunden-Lieferanten-Beziehung hinaus und trug wesentlich zum Gelingen des Projektes bei.

Beispielhaft war auch der Projektablauf. Ein detaillierter Projektplan mit vorgegebenem Budget konnte eingehalten werden. Der Projektfortschritt wurde durch ein Steering-Komitee bestehend aus Leuten der drei beteiligten Partner laufend überwacht. Gerade im nachhinein betrachtet, hat dieses Projekt Beispielcharakter für

- Mit diesen Daten erfolgen die Vorhersagen für EOS und Partner.
- Die Vorhersagen werden als Fax und als Files (E-mail) an EOS und Partner verschickt.

Dieses Verfahren funktionierte während mehrerer Monate (von Januar bis April 1996) praktisch ohne menschliches Eingreifen. Bei EOS wurden die Vorhersagen im Laufe der Zeit in die Planung einbezogen. Für einige der EOS-Partner wurde der Testbetrieb auf Wunsch nach April 1996 weiter aufrechterhalten.

Die beschriebene Lösung macht für die Datenübertragung Gebrauch vom Internet. Wollte man dem Benutzer mehr Flexibilität zugestehen, so bestünde die Möglichkeit einer flexibleren Implementierung unter Verwendung dieser Technologie (siehe Schlussfolgerung).

### Resultate

Die Ergebnisse der Vorhersagen vom 17. Januar bis 31. März 1996 wurden ausgewertet und mit den durch Planungsingenieure parallel dazu erstellten Vorhersagen verglichen. Die Vorhersage des neuronalen Netzes war statistisch betrachtet besser (Bilder 4 und 5). Die Auswertung erfolgte nach Wochentagen und nach Tageszeit. Erfahrungsgemäss sind die Vorhersagen zu bestimmten Zeiten schwieriger zu erstellen. Anfängliche Probleme mit Vorhersagen an den Wochenenden und an Montagen konnten erfolgreich gemeistert werden.

Die mittlere Genauigkeit der automatisierten Lastvorhersage betrug 2,2% für die Vorhersage des Gesamtnetzes, wobei die Temperaturvorhersagen der Schweizerischen Meteorologischen Anstalt benützt wurden (die Prozentangaben sind in Mape, d.h. Mean Average Percentage Error, zu verstehen). Hätte man exakte Temperaturen zur Verfügung gehabt, so wäre die Fehlerquote bei 1,9% gelegen. Bei Einzelvorhersagen für die Partnergesellschaften variierten die Fehler von

2,3–3,3%, beziehungsweise 2,1–2,7%. In ländlichen Gebieten oder Gegenden mit Rundsteuerungen (z. B. elektrische Heizung) gab es schlechtere Resultate. Wie bereits früher erwähnt, werden diese Informationen im gegenwärtigen Modell nicht berücksichtigt. Die Berücksichtigung von Rundsteuerprogrammen ist jedoch denkbar.

Es zeigte sich, dass die Resultate im Online-Betrieb leicht verschieden sind vom Offline-Test mit Archivdaten, wo die Spielregeln anders sind. In den Bildern 3–5 sind die Vorhersagefehler qualitativ dargestellt. Wie aus der Praxis bekannt ist, erwiesen sich gewisse Tageszeiten in der Vorhersage als heikler. Die Vorhersagen

Bild 4 Auswertung der Vorhersagefehler nach Wochentagen

EOS Vorhersagen für die Last  $P$  mit der Methode von EOS  
 NN vom neuronalen Netz gelieferte Prognosen

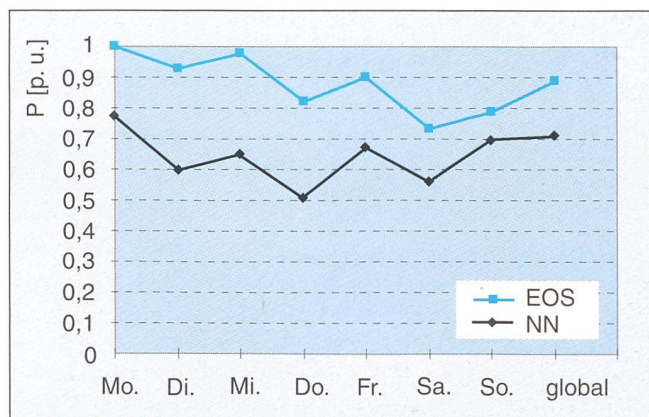



Bild 5 Auswertung der Vorhersagefehler nach Tageszeiten

EOS Vorhersagen für die Last  $P$  mit der Methode von EOS  
 NN vom neuronalen Netz gelieferte Prognosen





eine Zusammenarbeit zwischen Industrie und Forschung.

Ein wichtiges Nebenprodukt ist die im Abschnitt «Online-Testumgebung» beschriebene Testumgebung. Die Planungsingenieure konnten wirkungsvoll entlastet werden, indem eine automatisierte, den Anforderungen entsprechende Vorhersage zur Verfügung gestellt wurde. Die Lastvorhersage erfolgte gewissermassen als externe Dienstleistung. Man konnte zudem in sinnvoller Art und Weise für die Datenkommunikation das Internet verwenden. Dieses Konzept bietet kostenmässig grosse Vorteile für Anbieter und Benutzer. Im Falle der Lastvorhersage gibt es vielversprechende Argumente:

- Die Vorhersagemodelle werden zentral durch Experten mit Hilfe von Computern überwacht und verbessert. Für den Anbieter ist die Ressourcenauslastung gut planbar. Der Anwender ist stets auf dem neuesten Stand.
- Der Anwender ist grundsätzlich an Resultaten und nicht an Produkten interessiert. Investitionen in Personalschulung und für komplexe Tools würden durch günstigere Dienstleistungsgebühren ersetzt.
- Laufend verbesserte, leistungsfähige Kommunikationsnetze werden in Zukunft verfügbar sein, in der Art des Internets oder ähnlichen Privatnetzen.

Bei ABB Network Partner arbeitet man an neuen Projekten auf diesem Gebiet und ist überzeugt, dass hier ein grosses Zukunftspotential besteht.

### Literatur

- [1] P. Lajda and K. Reichert: An Interactive Short-Term Load Forecasting Programm. 7th PSCC (1981), Lausanne.
- [2] A. Germond, T. Macabrey et T. Baumann: Prédiction de charge dans un réseau électrique à l'aide du réseau de neurones de Kohonen. Bull. SEV/VSE 83(1992)5, pp. 13-19.
- [3] A. Piras, A. Germond, B. Buchenel et al.: Heterogeneous Artificial Neural Networks for Short-Term Load Forecasting. IEEE Transactions on Power Systems, Vol. 11, pp. 397-402 (1996).
- [4] G. Gross and F.D. Galiana: Short-Term Load Forecasting. Proc. of IEEE, vol. 75, pp. 1558-1573, 1987.
- [5] D.W. Bunn: Short-Term Forecasting: A Review of Procedures in the Electricity Supply Industry. J. Opl. Res. Soc., vol. 33, pp. 533-545, 1982.
- [6] I. Karanta and J. Ruusunen: Short-Term Load Forecasting in Communal Electric Utilities. University of Technology, Helsinki, Research Report A40, 1991.
- [7] S. Rahman and I. Drezga: Identification of a Standard for Comparing Short-Term Load Forecasting Techniques. Electric Power Systems Research, vol. 25, pp. 149-158, 1992.
- [8] T. Czernichow, A. Piras and M.M. Martin: Electrical Short-Term Load Forecasting with Artificial Neural Networks. EDF, Direction des Etudes et Recherches, Clamart EDF-DER HR-32/95/030, 1995, November 1995.

[9] A.D. Papalexopoulos, S. Hao and T.M. Peng: Short-Term System Load Forecasting Using an Artificial Neural Network. Proc. of ANNPS '93, pp. 239 to 244, 1993.

[10] A.D. Papalexopoulos, S. Hao and T.M. Peng: An Implementation of a Neural Network Based Load Forecasting Model for the EMS. IEEE PES '94 WM, 1994.

[11] M. Khadem: Application of the Kohonen Neural Network Classifier to Short-Term Load Forecasting. Proc. of IEEE PSWM Winter Meeting, Columbus (Ohio), 1993.

[12] T. Czernichow, B. Dorizzi, A. Germond et al.: Improving Recurrent Network Load Forecasting. Proc. of ICNN '95, pp. 899-904, 1995.

[13] M. Muller, M. Mangeas et N. Perrot: Synapse - Systeme neuronal d'anticipation de la puissance - guide d'utilisation. EDF 95NJ00035, 1994.

[14] F.D. Viron, F. Dongier and M. Monteyne: Automation, with Neural Network based Techniques, of Short-Term Load Forecasting at the Belgian National Control Center. Proc. of ANNPS '93, pp. 55-59, 1993.

[15] Y. Shimakura, Y. Fujisawa, Y. Maeda, M. Ono, J.-Y. Fann and N. Fukusima: Short-Term Load Forecasting Using Artificial Neural Networks. Proc. of ANNPS '93, pp. 233-238, 1993.

[16] T. Baumann, H. Strasser and H. Landrichter: Short-Term Load Forecasting Methods in Comparison: Kohonen Learning, Backpropagation Learning, Multiple Regression Analysis and Kalman Filters. Proc. of ISAP '94, pp. 445-451, Montpellier, 1994.

[17] M.C. Brace, V. Bui-Nguyen and J. Schmidt: Another Look at Forecast Accuracy of Neural Networks. Proc. of ANNPS '93, pp. 389-394, 1993.

[18] T. Matsumoto, S. Kitamura, Y. Ueki and T. Matsui: Short-Term Load Forecasting by Artificial Neural Networks Using Individual and Collective

Data of Preceding Years. Proc. of ANNPS '93, pp. 245-250, 1993.

[19] A. Piras, T. Czernichow, K. Imhof, P. Caire, Y. Jaccard and B. Dorizzi: A Review of Connectionist Models for Short-Term Load Forecasting. Invited Paper of the Industrial Session of ICANN 1995, pp. 1-11, Paris, 1995.

[20] A. Khotanzad, M. H. Davis, A. Abay and D.J. Maratukulam: An Artificial Neural Network Hourly Temperature Forecaster with Applications in Load Forecasting. Proc. of IEEE PES '95 SM, pp. 1-7, 95 SM 546-2 PWRS, Portland, OR, 1995.

[21] A. Khotanzad, R.C. Hwang and A. Abay: An Adaptive Modular Artificial Neural Network Hourly Load Forecaster and Its Implementation at Electric Utilities. Proc. of IEEE PES '95 WM, pp. 1-7, 95 WM 290-7 PWRS, New York, 1995.

[22] J. Bernasconi: Neuronale Netzwerke: Theorie und Praxis. Bull. SEV/VSE 82(1991)13, S. 11-16.

[23] R. R. Hocking: The Analysis and Selection of Variables in Linear Regression. Biometrics, vol. 32, pp. 1-49, 1976.

[24] C.N. Lu and S. Vemuri: Neural Network based Short-Term Load Forecasting. Proc. of IEEE PES '92 WM, pp. 1-7, New York, 1992.

### Verdankung

Die Verfasser danken Herrn P. Eckert von der Schweizerischen Meteorologischen Anstalt SMA für die kostenlose Bereitstellung der meteorologischen Daten im Rahmen des Forschungsprojektes. Die wertvolle Mitarbeit der Planungsleute von EOS, insbesondere der Herren Heiniger, Monod und Crosa, sei an dieser Stelle verdankt.

## Pronostics de la charge à l'aide de réseaux de neurones

### Prédiction de la charge horaire pour une période couvrant jusqu'à sept jours - un projet commun de EOS, EPFL et ABB

Le planning est une des tâches essentielles des entreprises d'électricité et il est la condition sine qua non d'un approvisionnement en énergie sûr, économique et ménageant les ressources. La prédiction de la charge est un élément primaire au début de tout planning. Selon l'objectif, la période couverte est différente. Dans l'article on discute de la prédiction de la charge pour une période allant de une heure à sept jours. Comme c'est généralement le cas pour la modélisation et la prédiction de processus non linéaires, l'utilisation de réseaux de neurones artificiels s'avère ici aussi très prometteuse.

Comme valeurs d'entrées on a utilisé dans le projet décrit ici les valeurs de charges (mesurées) des sept derniers jours, les valeurs des deux jours précédents, les minima et maxima des températures moyennes du jour précédent, les températures prédites pour le jour et comme indicateurs le jour de la semaine et le jour de l'année. Sur la base des grandeurs entrées on a modélisé la charge et la température séparément (formules 1-3). Une méthode automatisée selon la figure 2 a été implémentée pour l'exécution des tests en ligne. On a dépouillé les résultats des prédictions du 17 janvier jusqu'au 31 mars 1996 et les a comparés aux prédictions établies en parallèle par des ingénieurs d'études (figures 3-5). Avec une précision moyenne de 2,2% de la prédiction automatisée de la charge, valable pour l'ensemble du réseau, comparée aux écarts de 2,3 à 3,3% dans les pronostics établis de manière classique, le réseau de neurones s'en sort mieux en termes statistiques.



## Erfolgreiche Produkte unter neuem Namen.



**50 Jahre** Erfahrung  
*years* **experience**

Dieses Jahr feiern wir 50 Jahre Rundsteuerung.


Dieser langen Erfahrung in über 40 Ländern fühlen wir uns verpflichtet. Unter dem Namen unseres finnischen Mutterhauses werden wir auch in Zukunft Qualitätsstandards im Energie-Management setzen. Deshalb lautet unser Leitsatz heute:

**«Weltweit tätig – swiss made auch in Zukunft!»**

Statische Elektrizitätszähler sind in Zukunft auch in der Schweiz ein Erfolgsfaktor. Als Pionier auf diesem Gebiet hat sich Enermet schon lange europaweit einen Namen geschaffen. In unserem Produktsortiment für die Messung, Steuerung und Regelung von elektrischer Energie bieten wir unseren Kunden zudem eine umfassende Beratung im systemorientierten Anlagebau, die keine individuellen Wünsche offen lässt.

Lassen Sie sich von unseren Produkten, unserer Beratung und dem leistungsstarken Service rund um die Uhr überzeugen.

**«Wir sind immer in Ihrer Nähe.»**



# ENERMET




## Freiluftwandler 36 kV bis 145 kV

Ihr Vorteil, unsere Verpflichtung:

- beste Qualität
- hohe Betriebssicherheit
- minimale Abmessungen und Gewicht
- kompetente Beratung
- spezifische Lösungen

PFIFFNER Messwandler AG  
5042HIRSCHTHAL/SWITZERLAND  
TEL ..41 62 739 28 28 FAX ..41 62 739 28 10



SUISSE ROMANDE: SOTERO SA  
1114 Colombier, Tel. ...41 21 869 81 81



# ADALIN von ADASYS

Die Schweizer EW-Lösung  
zur optimalen Verwaltung  
von Stromnetzen

- Pläne aus Daten
- Daten und Bearbeitung nur einmal!
- Synergie-Effekte durch Kombination!
- ADA-ptive SYS-teme durch Standards!  
(Oracle, Interlis, DXF u.a)



ADASYS AG Kronenstrasse 38 8006 Zürich  
Tel. 01 363 19 39 Fax 01 363 53 73