



TECHNISCHE
UNIVERSITÄT
WIEN

Vienna University of Technology

DIPLOMARBEIT

Stochastische Einsatzoptimierung flexibler elektrischer Lasten

Ausgeführt bei der
Energy Economics Group (EEG)
am Institut für
Energiesysteme und Elektrische Antriebe
der Technischen Universität Wien

unter der Anleitung von
Privatdoz. Dipl.-Ing. Dr.techn. Johann Auer
und
Univ.Ass. Dipl.-Ing. Andreas Fleischhacker, BSc

durch
Viktor Zeh, BSc
Weyringergasse 6, 1040 Wien

Statutory Declaration

I declare that I have authored this thesis independently, that I have not used other than the declared sources/resources, and that I have explicitly marked all material which has been quoted either literally or by content from the used sources.

Wien, _____
Date

Signature

Eidesstattliche Erklärung

Ich erkläre an Eides statt, dass ich die vorliegende Arbeit selbstständig verfasst, andere als die angegebenen Quellen/Hilfsmittel nicht benutzt, und die den benutzten Quellen wörtlich und inhaltlich entnommenen Stellen als solche kenntlich gemacht habe.

Wien, am _____
Datum

Unterschrift

Abstract

The growing share of volatile electricity from renewable sources is threatening grid stability. One way of mitigating this risk is to modify consumer demand. Dynamic pricing and the possible increase in one's personal consumption are financial incentives to do so. For this purpose, a two stage stochastic optimization model is developed and evaluated by economical means for different customers. Results reveal savings in all scenarios. They are modest due to the fact that fluctuation of electricity prices are relatively small.

Kurzfassung

Der wachsende Anteil von volatilem Strom aus erneuerbaren Quellen ist eine Herausforderung für die Netzstabilität. Diese kann durch Anpassung des Verbrauchs an die Erzeugung zum Teil gelöst werden. Dynamische Strompreise sowie die Möglichkeit den Eigenverbrauch zu erhöhen sind monetäre Anreize dafür. Zu diesem Zweck wird ein Prognose- und Optimierungsmodell zur Verlagerung elektrischer Lasten erstellt, für unterschiedliche Kunden simuliert und abschließend ökonomisch bewertet. Die Ergebnisse zeigen in allen Fällen Einsparungen, auch wenn diese aufgrund der geringen Schwankungen im Strompreis überschaubar sind.

Inhaltsverzeichnis

1	Einleitung	1
2	State of the Art	3
2.1	Demand-Side-Management	3
2.2	Dynamischer Stromtarif	4
2.3	Lastprognose	4
2.4	Beitrag dieser Arbeit	4
3	Künstliche Neuronale Netze	7
3.1	Das Multilayer Perceptron zur Prognose	7
3.1.1	Aufbau und Informationsfluss	7
3.1.2	Das Neuron	9
3.1.3	Lernphase	10
3.1.4	Datenaufbereitung	17
3.1.5	Prognose um mehrere Zeitschritte in die Zukunft	17
4	Optimierungsmodell	19
4.1	Deterministisches Optimierungsmodell	19
4.1.1	Modellaufbau	19
4.1.2	Verschiebbare Lasten mit festem Profil	20
4.1.3	Unterbrechbare Lasten	23
4.1.4	Stationärer Stromspeicher	27
4.1.5	Erzeugungsanlage und Stromnetz	28
4.1.6	Zielfunktion	28
4.2	Anwendung des zweistufigen Optimierungsmodelles in der Praxis	29

Inhaltsverzeichnis

5 Fallstudien - Ausgangslage	31
5.1 Datengrundlage	31
5.1.1 Verbrauchsprofile	31
5.1.2 Flexible Lasten	35
5.1.3 Erzeugungsprofil - Photovoltaik	37
5.1.4 Strompreis	37
5.2 Modellierungssoftware	38
5.3 Performancevergleich verschiedener künstlicher neuronaler Netze	39
6 Fallstudien - Ergebnisse	47
6.1 Haushalt	47
6.2 Bürohaus	49
6.3 Gastronomiebetrieb	52
7 Schlussfolgerungen	55
Literatur	57

1 Einleitung

In den letzten Jahren hat der Anteil erneuerbarer Energie aus Wind und Sonne im europäischen Strommarkt deutlich zugenommen. Neben den positiven Auswirkungen auf Umwelt und Handelsbilanz stellt die volatile und nicht steuerbare Einspeisung die Netzbetreiber vor erhebliche Probleme. Um die Versorgungssicherheit auch in Zukunft gewährleisten zu können, wird es unabdingbar sein, die Stromnetze intelligenter zu machen. Das bedeutet vor allem, dass der Verbrauch stärker an die Erzeugung angepasst werden muss. Eine zentrale Voraussetzung dafür sind selbstverständlich verlässliche Prognosen.

Ziel dieser Arbeit ist es, ein stochastisches Optimierungstool zu erstellen, das verschiedene Arten von elektrischen Lasten einer Anlage so verschiebt, dass die Kosten minimiert werden. Zusätzlich soll der ökonomische Nutzen eines solchen Tools anhand verschiedener Szenarien bewertet werden. Dabei können sowohl die Preisschwankungen eines dynamischen Stromtarifs als auch die Möglichkeit der Erhöhung des Eigenverbrauchs lokal erzeugten Stromes aus einer Photovoltaikanlage genutzt werden.

Das stochastische Problem wird dabei in zwei Stufen realisiert: ein künstliches neuronales Netz liefert die Prognose, die als Eingangswert für ein gemischt-ganzzahliges Optimierungsmodell dient. Um einen möglichst praxisnahen Fall zu untersuchen, wird dabei nur der Verbrauch aller nicht verschiebbaren Lasten der Anlage endogen prognostiziert. Die Strompreise werden ohnehin um 14 Uhr für den gesamten nächsten Tag bekannt gegeben, für den lokal erzeugten Solarstrom existieren bereits sehr genaue und räumlich hochauflösende Prognosen. Diese beiden Zeitreihen werden dem Optimierungsmodell daher als exogene Parameter übergeben.

Die Arbeit ist folgendermaßen aufgebaut: Kapitel 2 gibt einen Überblick über den aktuellen Stand der Technik. In Kapitel 3 und 4 wird das zweistufige

1 Einleitung

stochastische Optimierungsmodell beschrieben. Kapitel 5 erläutert die für die Fallstudien verwendeten Daten und vergleicht die Performance unterschiedlicher Prognosenmodelle. In Kapitel 6 werden die Ergebnisse der Fallstudien diskutiert. Abschließend bietet Kapitel 7 Schlussfolgerungen sowie einen Ausblick auf offene Fragen.

2 State of the Art

Dieses Kapitel gibt einen kurzen Einblick in den aktuellen Stand der Technik und die bereits vorhandenen Methoden.

2.1 Demand-Side-Management

Um den Strommarkt im Gleichgewicht zu halten, müssen Angebot und Nachfrage an elektrischer Energie zu jeder Zeit übereinstimmen. Unter Demand-Side-Management versteht man die Anpassung der Angebotsseite. Mathematisch handelt es sich dabei in der Regel um gemischt-ganzzahlige Optimierungsmodelle. In [2] wird ein Überblick einiger relevante Methoden gegeben.

Demand-Side-Management an sich ist nicht neu. Bis vor Kurzem war dies allerdings nur für große Verbraucher, die über einen Lastprofilzähler verfügen, möglich. Haushalte oder andere kleinere Stromkunden konnten höchstens über den Regenergiemarkt oder über starre Hoch- und Niedertarifzeiten am Verschieben von Lasten verdienen.

Da aber mittlerweile auch immer mehr Smart Meter installiert werden und die Marktregeln [16] dahingehend angepasst wurden, dass es für alle Kunden möglich ist den tatsächlichen Verbrauch im Clearing zu berücksichtigen, findet Demand-Side-Management bei immer breiteren Kundengruppen Anwendung.

2.2 Dynamischer Stromtarif

Auf Grundlage von diesen technischen und regulatorischen Rahmenbedingungen bietet die aWATTar GmbH einen stündlich-variablen Stromtarif für Kunden aller Verbrauchsklassen an. Dabei wird im Wesentlichen der Spotmarktpreis weitergegeben. Die Preise für den Folgetag werden um 14 Uhr bekannt gegeben.

Da die Korrelation zwischen dem Anteil an Wind- sowie Sonnenstrom im Netz und dem Strompreis klar negativ ist, wird so ein monetärer Anreiz geschaffen, den Verbrauch in Stunden hoher Einspeisung aus Erneuerbaren zu verlagern.

2.3 Lastprognose

Während die Prognose des Strombedarfs größerer geographischer Einheiten wie Städten oder Ländern relativ zuverlässige Ergebnisse liefert, gilt die Vorhersage des Verbrauchs einzelner Kunden aufgrund der hohen Volatilität und Zufälligkeit als schwierig.

In [11] wird sogar behauptet, dass für Haushalte komplexe Modelle kaum Vorteile gegenüber simplen Durchschnittswerten bieten. In [4] wird diese These allerdings widerlegt, indem gezeigt wird, dass künstliche neuronale Netze bessere Ergebnisse liefern. Speziell das sogenannte Multilayer Perceptron hat sich als hilfreich erwiesen, weshalb es auch die Grundlage für die Untersuchungen dieser Arbeit bildet.

2.4 Beitrag dieser Arbeit

Es soll ein Prognosenmodell entwickelt werden, das ohne große Anpassung an den Kunden robuste Ergebnisse liefert¹. Dieses soll zu einem zweistufigen

¹der in [4] vorgestellte Ansatz benötigt wie viele vergleichbare Arbeiten eine aufwendige Analyse, welche Wochentage ähnliche Lastverläufe haben, sowie für ein eigenes neuronales Netz für jede Kategorie

2.4 Beitrag dieser Arbeit

stochastischen Optimierungsmodell für die Lastverlagerung erweitert werden. Abschließend soll der wirtschaftliche Nutzen eines solchen Systems beurteilt werden.

3 Künstliche Neuronale Netze

Wie bereits in Kapitel 2 beschrieben, haben sich künstliche neuronale Netze als besonders geeignet für die Vorhersage elektrischer Lasten erwiesen.

Darunter versteht man vereinfachte Modelle der informationsverarbeitenden Abläufe im menschlichen Gehirn. Sie bestehen aus vielen, relativ simplen *Neuronen*, die sich Daten über gewichtete Verbindungen zusenden. Die einzelnen Neuronen können dabei lediglich die Eingangswerte summieren und eine Aktivierungsfunktion anwenden um die Ausgabewerte zu bestimmen, die sie im Anschluss an die nächste Schicht übergeben.

3.1 Das Multilayer Perceptron zur Prognose

In den folgenden Abschnitten wird eine spezielle Form eines künstlichen neuronalen Netzes, das sogenannte Multilayer Perceptron, näher beschrieben.

3.1.1 Aufbau und Informationsfluss

Je nach Anwendung kann das Aussehen eines neuronalen Netzes sehr unterschiedlich sein. Das in dieser Arbeit verwendete Multilayer Perceptron hat aber stets den in Abbildung 3.1 dargestellten Aufbau:

- eine Eingangsschicht, deren Anzahl an Neuronen gleich der Anzahl der Prädiktoren ist,
- eine oder mehrere versteckte Schichten mit beliebiger Neuronenanzahl sowie
- eine Ausgangsschicht mit genau einem Neuron.

3 Künstliche Neuronale Netze

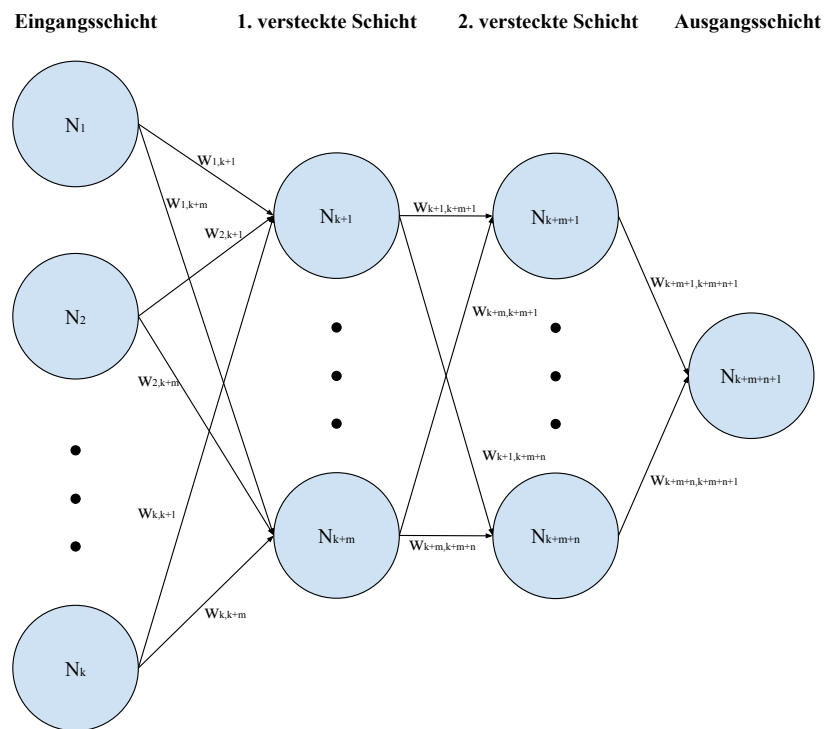


Abbildung 3.1: Aufbau eines künstlichen neuronalen Netzes mit k Neuronen in der Eingangsschicht, zwei versteckten Schichten mit m beziehungsweise n Neuronen, sowie einem Neuron in der Outputschicht

3.1 Das Multilayer Perceptron zur Prognose

Notation	
x_j	Eingabe in das j -te Neuron der Eingangsschicht
o_j	Ausgabe des j -ten Neurons
b_s	Bias der s -ten Schicht
$w_{i,j}$	Gewicht für die Verbindung vom i -ten zum j -ten Neuron
v_j	Netzeingabe des j -ten Neurons
Λ	Menge aller verfügbarer Datenpaare
Λ^t	Trainingsmenge
Λ^v	Validierungsmenge
\mathbf{x}_λ	Prädiktor für Datenpaar $\lambda \in \Lambda$
y_λ	Antwort für Datenpaar $\lambda \in \Lambda$
E^λ	Fehler für Datenpaar $\lambda \in \Lambda$
E	Summe der Fehler aller Datenpaare $\lambda \in \Lambda$
$\Delta w_{i,j}$	Änderung des Gewichtes $w_{i,j}$
μ	Schrittweite

Tabelle 3.1: Notation für Bestandteile neuronaler Netze

Die Verbindungen von jedem Neuron zu allen Neuronen der nächsten Schicht sind gewichtet und werden bei der Prognose nur nach vorne durchlaufen. Man spricht deshalb von einem Netz ohne Rückkopplung oder einem feedforward Netz.

Bevor ein künstliches neuronales Netz Prognosen liefert, müssen anhand historischer Paare aus Prädiktoren und Antwortvariable die Parameter eingestellt werden. Diese sogenannte Lernphase und die Berechnungen in den einzelnen Schichten werden in den folgenden Abschnitten näher diskutiert.

3.1.2 Das Neuron

Je nach Schicht, in welcher sich ein Neuron befindet, hat es unterschiedliche Aufgaben. In der Eingangsschicht werden lediglich die Werte übernommen und über gewichtete Verbindungen zu jedem Neuron der nächsten Schicht weitergeleitet. Die Ausgabe o_j für das j -te Neuron entspricht also einfach dem Eingangsparameter x_j , als Gleichung geschrieben also

$$o_j = x_j . \quad (3.1)$$

3 Künstliche Neuronale Netze

In den versteckten Schichten, werden die Ausgaben der k Neuronen der vorigen Schicht gewichtet und summiert. Dazu wird ein sogenanntes *Bias* b_s addiert, der innerhalb jeder Schicht s derselbe ist. Auf die Summe wird im Anschluss der Tangens Hyperbolicus als Aktivierungsfunktion angewandt. Die Ausgabe des j -ten Neurons ergibt sich also aus

$$o_j = \tanh \left(\sum_{i=1}^k o_i \cdot w_{i,j} + b_s \right). \quad (3.2)$$

Dabei wird $\sum_{i=1}^k o_i \cdot w_{i,j} + b_s$ auch Netzeingabe des j -ten Neurons genannt und im weiteren Verlauf mit v_j bezeichnet.




Abbildung 3.2: Der Tangens Hyperbolicus dient als Aktivierungsfunktion in den versteckten Schichten

Das Neuron in der Ausgangsschicht summiert lediglich noch die gewichteten Ausgaben der m Neuronen der letzten versteckten Schicht und ein Bias b_s . Die Antwort y des künstlichen neuronalen Netzes erhält man demnach durch

$$y = \sum_{i=1}^m o_i \cdot w_{i,j} + b_s. \quad (3.3)$$

3.1.3 Lernphase

Die Gewichte und Bias werden anhand von Paaren von historischen Prädiktoren x_λ und zugehörigen Antworten y_λ eingestellt. Da die tatsächlichen

3.1 Das Multilayer Perceptron zur Prognose

Antworten dieser Daten vorliegen, gehört dieses Verfahren zu jenen des überwachten Lernens.

Die verfügbaren Datenpaare $(x_1, y_1), \dots, (x_\Lambda, y_\Lambda)$ werden zu diesem Zweck in zwei disjunkte Mengen aufgeteilt. Dabei werden (x_λ, y_λ) für $\lambda \in (1, \dots, \Lambda^t)$ zum Trainieren, also zum Einstellen der Gewichte verwendet. Der Rest, also (x_λ, y_λ) für $\lambda \in (\Lambda^t + 1, \dots, \Lambda^v)$, wird für die Validierung benötigt. Das Verhältnis zwischen Trainings- zu Validierungsdaten soll dabei ca. siebenzig zu dreißig betragen. Durch diese Aufteilung soll verhindert werden, dass die Gewichte des Netzes zu sehr auf die Testdaten zugeschnitten werden. Weitere Details zu diesem in der Literatur als *Overfitting* bekannten Phänomens folgen in den nächsten Kapiteln.

Der Lern-Algorithmus

Betrachtet man den (halben¹) quadratischen Abstand zwischen tatsächlicher Antwort y_λ^t und Ausgabe des künstlichen neuronalen Netzes y_λ summiert über alle Λ^t Datenpaare (x_λ, y_λ) , also

$$E = \sum_{\lambda=1}^{\Lambda^t} E_\lambda = \sum_{\lambda=1}^{\Lambda^t} \frac{1}{2} (y_\lambda - y_\lambda^t)^2 \quad (3.4)$$

als Funktion aller seiner n Gewichte und m Bias, so kann man diesen Fehler graphisch auftragen und erhält eine $n + m$ -dimensionale Hyperfläche. Abbildung 3.3 veranschaulicht den zweidimensionalen Fall.

Mit dem *Backpropagation-Algorithmus*, einem Gradientenabstiegsverfahren, wird das globale Minimum dieser Fehlerhyperfläche in Richtung des steilsten Abstiegs gesucht. Eine zentrale Rolle spielt dabei die Backpropagation-Regel, die im folgenden Abschnitt hergeleitet wird.

Bemerkung 3.1 *Wie bei allen Gradientenabstiegsverfahren bestehen auch beim Backpropagation-Algorithmus eine Reihe von Risiken. So kann es passieren, dass man*

1. *in einem lokalen Minimum hängen bleibt,*

¹Der Faktor $\frac{1}{2}$ bietet in der Folge Vereinfachungen in der Notation

3 Künstliche Neuronale Netze




Abbildung 3.3: Fehlerfläche eines künstlichen neuronalen Netzes als Funktion zweier Gewichte

2. in flachen Regionen mit sehr niedrigem Gradienten verharret,
3. in eine Oszillation in einem steilen Tal verfällt oder
4. ein globales Minimum überspringt.

Daher empfiehlt es sich den Algorithmus mit unterschiedlichen Initialgewichten zu wiederholen.

Bemerkung 3.2 Außerdem ist darauf zu achten, dass die Gewichte einer Schicht nicht gleich groß gewählt werden. Der Backpropagation-Algorithmus würde in diesem Fall die Gewichte in der Schicht, die der Ausgangsschicht vorgelagert ist, stets in gleichem Ausmaß ändern. Dieses Phänomen wird in der Literatur als *symmetry breaking* bezeichnet.

Der Algorithmus läuft nun nach dem folgenden Schema ab:

1. Die Gewichte werden mit Zufallswerten initialisiert. Bias werden dabei wie Gewichte behandelt, deren zu gewichtende Ausgabe konstant 1 ist.

3.1 Das Multilayer Perceptron zur Prognose

2. Das künstliche neuronale Netz wird für ein $\lambda \in \{1, \dots, \Lambda^t\}$ mit \mathbf{x}_λ durchlaufen.
3. $\Delta^\lambda w_{i,j}$ ² wird für alle i und j mit der Backpropagation-Regel aus dem Nächsten Abschnitt berechnet.
4. Schritte 2 und 3 werden für alle $\lambda \in \{1, \dots, \Lambda^t\}$ wiederholt.
5. Alle Gewichte und Bias werden nach der Formel

$$w_{i,j} = w_{i,j} + \Delta w_{i,j} = w_{i,j} + \sum_{\lambda=1}^{\Lambda^t} \Delta^\lambda w_{i,j} \quad (3.5)$$

angepasst.

6. Die Schritte 2 bis 5 werden wiederholt, bis ein Abbruchkriterium erreicht ist. Eine Wiederholung heißt dabei auch Iteration. Welche Arten von Kriterien verwendet werden, wird in einem der nächsten Abschnitte näher beschrieben.
7. Die ersten fünf Schritte werden mehrfache wiederholt und das Netz mit der besten Performance wird ausgewählt. Dies lindert die in Bemerkung 3.1 beschriebenen Probleme.

Bemerkung 3.3 Die Herangehensweise das Netz mit allen Trainingsdatenpaaren $(\mathbf{x}_\lambda, y_\lambda)$ für $\lambda \in (1, \dots, \Lambda^t)$ durchlaufen zu lassen, $\Delta w_{i,j}$ für alle i und j zu bestimmen und erst dann die Gewichte zu ändern wird in der Literatur als *offline- oder batch-Trainingsverfahren* bezeichnet. Das Gegenstück wäre ein *online-Verfahren*, bei dem die Gewichte nach der Formel

$$w_{i,j} = w_{i,j} + \Delta^\lambda w_{i,j} \quad (3.6)$$

nach jedem Datenpaar $(\mathbf{x}_\lambda, y_\lambda)$ angepasst werden.

Die Backpropagation-Regel

Die hier angewandte Backpropagation-Regel geht auf Rubelhart, Hinton und Williams zurück, die es mit ihrer Arbeit [9] erstmals ermöglichten Perceptrons mit mehreren Lagen und nichtlinearer Aktivierungsfunktion zu trainieren.

²der Index λ zeigt, dass um Werte für das Datenpaar $\mathbf{x}_\lambda, y_\lambda$ handelt

3 Künstliche Neuronale Netze

Die im Folgenden gebrachte Herleitung orientiert sich aber vor allem an der Darstellung aus [12].

Interpretiert man die Bias als Gewichte, deren zu gewichtende Ausgabe konstant 1 ist, kann die Netzeingabe $v_{j,\lambda}$ des j -ten Neurons geschrieben werden als

$$v_{j,\lambda} = \sum_{i=1}^k o_{i,\lambda} \cdot w_{i,j} + b_s = \bar{o}_{j,\lambda} \cdot w_{k+1,j} + \sum_{i=1}^k o_{i,\lambda} \cdot w_{i,j}, \quad (3.7)$$

mit $\bar{o}_{j,\lambda} = 1$ und $w_{k+1,j} = b_j$. Die Grundidee besteht nun darin, alle Gewichte nach der Formel

$$w_{i,j} = w_{i,j} + \Delta w_{i,j} \quad (3.8)$$

mit

$$\Delta w_{i,j} = - \sum_{\lambda=1}^{\Lambda^t} \mu \cdot \frac{\partial E_\lambda}{\partial w_{i,j}} \quad (3.9)$$

anzupassen. Die Schrittweite μ ist ein Wert aus dem Intervall $(0, 1]$, der einen regularisierenden Effekt hat. Es kann auch vorkommen, dass eine größere Schrittweite vorteilhaft ist, in dieser Arbeit findet man mit den erwähnten Werten jedoch das Auslangen. Wendet man nun die Kettenregel auf den zweiten Faktor der rechten Seite von (3.9) an, so erhält man

$$\frac{\partial E_\lambda}{\partial w_{i,j}} = \frac{\partial E_\lambda}{\partial v_{j,\lambda}} \cdot \frac{\partial v_{j,\lambda}}{\partial w_{i,j}} = \frac{\partial E_\lambda}{\partial v_{j,\lambda}} \cdot o_{i,\lambda}. \quad (3.10)$$

Mit der Notation

$$\delta_{j,\lambda} = - \frac{\partial E_\lambda}{\partial v_{j,\lambda}} \quad (3.11)$$

lässt sich (3.9) schreiben als

$$\Delta w_{i,j} = \mu \sum_{\lambda=1}^{\Lambda^t} o_{i,\lambda} \cdot \delta_{j,\lambda}. \quad (3.12)$$

Weiters gilt nach erneuter Anwendung der Kettenregel

$$\delta_{j,\lambda} = - \frac{\partial E_\lambda}{\partial v_{j,\lambda}} = - \frac{\partial E_\lambda}{\partial o_{j,\lambda}} \cdot \frac{\partial o_{j,\lambda}}{\partial v_{j,\lambda}}. \quad (3.13)$$

3.1 Das Multilayer Perceptron zur Prognose

Für die Berechnung des ersten Faktors der rechten Seite von (3.13) muss zwischen den Gewichten vor Neuronen der Ausgangs- und der versteckten Schichten unterschieden werden. Ist j der Index des Neurons der Ausgangsschicht, erhält man durch Verwendung von (3.4) unmittelbar³

$$-\frac{\partial E_\lambda}{\partial o_{j,\lambda}} = (y_\lambda^t - o_{j,\lambda}) \quad (3.14)$$

Ist j hingegen Index eines Neurons einer versteckten Schicht, ist die Berechnung etwas aufwendiger. Die Kettenregel liefert in diesem Fall

$$-\frac{\partial E_\lambda}{\partial o_{j,\lambda}} = -\sum_k \frac{\partial E_\lambda}{\partial v_{k,\lambda}} \cdot \frac{\partial v_{k,\lambda}}{\partial o_{j,\lambda}} = \sum_k \delta_{k,\lambda} \cdot w_{j,k}, \quad (3.15)$$

wobei k in den Summen die Indizes aller Neuronen der nächsten Schicht in Richtung Ausgangsschicht durchläuft. Der Fehler des j -ten Neurons wird also aus den gewichteten Fehlern $\delta_{k,\lambda}$ sämtlicher Nachfolgezellen und der Gewichte der Verbindungen zu diesen berechnet. Wegen

$$o_{j,\lambda} = \tanh(v_{j,\lambda}) \quad (3.16)$$

gilt für den zweiten Faktor der rechten Seite von (3.13)

$$\frac{\partial o_{j,\lambda}}{\partial v_{j,\lambda}} = \frac{\partial}{\partial v_{j,\lambda}} \tanh(v_{j,\lambda}) = 1 - \tanh^2(v_{j,\lambda}) \quad (3.17)$$

Insgesamt erhält man also die Formel für die Anpassung der Gewichte

$$\Delta w_{i,j} = \mu \sum_{\lambda=1}^{\Lambda^t} o_{i,\lambda} \cdot \delta_{j,\lambda}, \quad (3.18)$$

mit

$$\delta_{j,\lambda} = \begin{cases} (1 - \tanh^2(v_{j,\lambda})) \cdot (y_\lambda^t - o_{j,\lambda}), & \text{falls Neuron } j \text{ in der Ausgangsschicht liegt} \\ (1 - \tanh^2(v_{j,\lambda})) \cdot \sum_k \delta_{k,\lambda} \cdot w_{j,k}, & \text{sonst.} \end{cases} \quad (3.19)$$

³Die Ausgabe $o_{j,\lambda}$ des Neurons in der Ausgangsschicht ist gleich der Ausgabe y_λ^t des Netzes

3 Künstliche Neuronale Netze

Abbruchkriterien

Der Algorithmus wird nach einer vorgegebenen Zahl an Iterationen, typischerweise 1000, abgebrochen. Bei Eintritt eines der folgenden Kriterien kommt es allerdings zu einem vorzeitigen Abbruch:




Abbildung 3.4: Fehlerfläche eines künstlichen neuronalen Netzes als Funktion zweier Gewichte

1. Der Gradient ist kleiner als 10^{-5} .
2. Der Fehler für die Validierungsdatenpaare $(\mathbf{x}_\lambda, y_\lambda)$ mit $\lambda \in (\Lambda^t + 1, \dots, \Lambda^v)$ verbessert sich über eine vorgegebene Anzahl aufeinanderfolgender Iterationen nicht, hier ist sechs ein typischer Wert.

Die zweite Abbruchbedingung hat dabei den Zweck ein sogenanntes Overfitting, also eine zu gute Approximation an die Testdatenpaare auf Kosten der Generalisierung, zu verhindern. Abbildung 3.4 veranschaulicht diesen Mechanismus.

3.1.4 Datenaufbereitung

Um eine Prognose für eine Zeitreihe erstellen zu können muss ebendiese entsprechend aufbereitet werden. Für historische Daten $\{\chi_1, \dots, \chi_n\}$ und ein künstliches neuronales Netz mit k Neuronen in der Eingangsschicht lassen sich folgende Paare aus Prädiktoren \mathbf{x} und Antworten y erstellen

$$\mathbf{x}_1 = \begin{Bmatrix} \chi_1 \\ \chi_2 \\ \chi_3 \\ \vdots \\ \chi_k \end{Bmatrix}, y_1 = \chi_{k+1}, \dots, \mathbf{x}_{n-k} = \begin{Bmatrix} \chi_{n-k} \\ \chi_{n-k+1} \\ \chi_{n-k+2} \\ \vdots \\ \chi_{n-1} \end{Bmatrix}, y_{n-k} = \chi_n. \quad (3.20)$$

Diese $k - n$ Datenpaare werden nun zufällig im Verhältnis 70:30 aufgeteilt. Die größere Teilmenge wird zum Trainieren des künstlichen neuronalen Netzes eingesetzt, der Rest für die Validierung.

3.1.5 Prognose um mehrere Zeitschritte in die Zukunft

Das künstliche neuronale Netz liefert immer nur einen skalaren Wert. Für die Optimierung ist es allerdings nötig, mehr als eine Periode in die Zukunft zu blicken. Daher wird das Prognosenmodell nach dem folgenden Schema mehrmals bemüht⁴:

$$\begin{aligned} \{\chi_1, \chi_2, \chi_3, \dots, \chi_k\}^T &\rightarrow \chi_{k+1}^* \\ \{\chi_2, \chi_3, \chi_4, \dots, \chi_k, \chi_{k+1}^*\}^T &\rightarrow \chi_{k+2}^* \\ \{\chi_3, \chi_4, \chi_5, \dots, \chi_k, \chi_{k+1}^*, \chi_{k+2}^*\}^T &\rightarrow \chi_{k+3}^* \\ &\vdots \\ \{\chi_m, \chi_{m+1}, \dots, \chi_{k+m-1}, \chi_{k+m}^*\}^T &\rightarrow \chi_{k+m+1}^* \end{aligned} \quad (3.21)$$

Die erste Iteration liefert also eine Prognose, die in der zweiten Iteration selbst als Eingangswert dient. Mit jeder Iteration werden die die Eingangswerte, die tatsächlich gemessen wurden weniger.

⁴Der hochgestellte * kennzeichnet dabei prognostizierte Werte

4 Optimierungsmodell

Die Unsicherheit bezüglich der Eingangswerte für das Optimierungsmodell wird durch ein zweistufiges Verfahren behandelt. Das bedeutet, dass zu jeder Stunde ein neuronales Netz - wie im vorigen Kapitel erläutert - eine Prognose für die relevanten Werte erzeugt, bevor eine deterministische Optimierung die konkreten Schaltempfehlungen für die elektrischen Anwendungen ermittelt.

Zunächst wird dafür dieses deterministische Optimierungsmodell entwickelt. Dabei werden auch die Arten von verschiebbaren elektrischen Lasten erklärt.

4.1 Deterministisches Optimierungsmodell

Um in jedem Zeitschritt des Planungshorizontes $t \in \{1, \dots, T\}$ - typischerweise handelt es sich hierbei um 60 Minuten Intervalle beziehungsweise 24 Stunden Fenster - das kostenoptimale Betriebsprogramm eines Stromkunden unter Berücksichtigung sämtlicher relevanter dynamischer Parameter zu ermitteln, wird ein gemischt-ganzzahliges, lineares Optimierungsmodell erstellt. Dieses bedient sich zum Teil der Methoden aus [1],[2] und [5].

4.1.1 Modellaufbau

Betrachtet wird eine Anlage, die über

- nicht verschiebbare (festen) Lasten,
- zwei Kategorien von flexible Lasten, nämlich
 - solche mit vorgegebenem Profil und
 - unterbrechbare,

4 Optimierungsmodell

- einen stationären Speicher sowie
- eine Einrichtung zur Erzeugung elektrischer Energie aus erneuerbaren Quellen, beispielsweise Wind oder Sonne, deren Leistung nicht gesteuert werden kann

verfügt.

In den folgenden Unterabschnitten werden diese Teile der Anlage näher beschrieben und mathematisch modelliert. Abschließend werden Nebenbedingungen, die die Erzeugungsanlage sowie Bezug und Einspeisung aus dem beziehungsweise in das Stromnetz betreffen, erörtert. Dadurch erhält man ein gemischt-ganzzahliges, lineares Optimierungsproblem, das unter Berücksichtigung aller Anforderungen den kostenoptimalen Betrieb der Anlage ermöglicht.

4.1.2 Verschiebbare Lasten mit festem Profil

Eine Anwendung n aus der Kategorie N der verschiebbaren Lasten mit festem Profil wird durch einen Lastgang $\Pi^n = \{\pi_1^n, \dots, \pi_{d_n}^n\}$ sowie einen frühest möglichen Zeitpunkt zum Einschalten $T_{\text{ein,min}}^n$ und eine spätest möglichen Endzeit $T_{\text{aus,max}}^n$ beschrieben. Die Leistung während jedem der d_n Zeitfenster wird als konstant angenommen.

Das Optimierungsmodell entscheidet also lediglich über den Zeitpunkt des Einschaltens. Um diesen im Modell zu erfassen, bieten sich für $t \in \{1, \dots, T\}$ und $n \in N$ binäre Variablen s_t^n mit

$$s_t^n = \begin{cases} 1, & \text{falls Anwendung } n \text{ während } t \text{ eingeschaltet wird} \\ 0, & \text{sonst} \end{cases} \quad (4.1)$$

an.

Die Nebenbedingungen

$$\sum_{k=T_{\text{ein,min}}^n}^{T_{\text{aus,max}}^n-d_n+1} s_k^n = 1, \quad \forall n \in N \quad (4.2)$$

4.1 Deterministisches Optimierungsmodell

Parameter	
T	Anzahl der Zeitfenster, über die optimiert wird
τ	Länge eines solchen Zeitfensters [h]
p_t	Preis für Strom, der während t aus dem Netz bezogen wird [Euro/kWh]
q_t	Erlös für Strom, der während t in da Netz eingespeist wird [Euro/kWh]
g_t	Prognose für die lokale Stromerzeugung während t [kWh]
f_t	Prognose für den akkumulierten Verbrauch aller festen Lasten während t [kWh]
P_{max}	maximaler Bezug aus dem Netz [kW]
N	Klasse der verschiebbaren Anwendungen
Π^n	Lastgang von $n \in N$
d_n	Länge von Π_n
π_k^n	Verbrauch von $n \in N$ während des k -ten Zeitfensters seines Lastganges Π^n [kWh]
$T_{\text{ein,min}}^n$	frühes möglicher Startzeitpunkt von $n \in N$
$T_{\text{aus,max}}^n$	spätest möglichen Endzeitpunkt von $n \in N$
M	Klasse der unterbrechbaren Lasten
P^m	Leistung von $m \in M$ [kW]
T_{aus}^m	Mindeststandzeit nach dem Ausschalten von $m \in M$ [Zeitfenster]
T_{ein}^m	Mindestlaufzeit nach dem Einschalten von $m \in M$ [Zeitfenster]
\underline{T}^m	Mindestanzahl von Zeitfenstern, während derer $m \in M$ laufen muss
\bar{S}^m	maximale Anzahl von Ein- und Ausschaltvorgängen von $m \in M$
$t_{\text{ein},0}^m$	Anzahl von Zeitfenstern, die $m \in M$ vor Beginn der Optimierung bereits gelaufen ist
$t_{\text{aus},0}^m$	Anzahl von Zeitfenstern, die $m \in M$ vor Beginn der Optimierung bereits gestanden ist
z_0^m	Zustand von $m \in M$ unmittelbar vor der Optimierung
X	obere Schranke für alle $t_{\text{ein},t}^m$ und $t_{\text{aus},t}^m$ ($t \in \{1, \dots, T\}$, $m \in M$)
w_l	Wirkungsgrad beim Laden des stationären Stromspeichers [Prozent]
w_e	Wirkungsgrad beim Entladen des stationären Stromspeichers [Prozent]
l_{\max}	maximale Energiemenge, die während eines Zeitfensters geladen werden kann [kWh]
e_{\max}	maximale Energiemenge, die während eines Zeitfensters entladen werden kann [kWh]
\bar{B}	Kapazität, bis zu welcher der Speicher geladen werden kann [kWh]
\underline{B}	Kapazität, bis zu welcher der Speicher entladen werden kann [kWh]
B_0	Ladezustand des Speichers zu Beginn der Optimierung [kWh]

Tabelle 4.1: Parameter des Optimierungsmodells mit Einheiten in eckigen Klammern

4 Optimierungsmodell

Entscheidungsvariablen	
ϕ_t	Eigenverbrauch des lokal erzeugten Stroms während t [kWh]
η_t	Netzeinspeisung des lokal erzeugten Stroms während t [kWh]
β_t	Bezug aus dem Stromnetz während T [kWh]
s_t^n	bildet das Einschalten von $n \in N$ ab [binär]
v_t^n	Verbrauch von $n \in N$ während t [kWh]
z_t^m	Zustand von $m \in M$ während t [binär]
e_t^m	bildet das Einschalten von $m \in m$ ab [binär]
a_t^m	bildet das Ausschalten von $m \in M$ ab [binär]
$t_{\text{ein},t}^m$	Anzahl von Zeitfenstern, die $m \in M$ zum Zeitpunkt t läuft
$t_{\text{aus},t}^m$	Anzahl von Zeitfenstern, die $m \in M$ zum Zeitpunkt t steht
g_t^m	Hilfsvariable mit dem Wert $z_t^m \cdot t_{\text{ein},t}^m$
h_t^m	Hilfsvariable mit dem Wert $z_t^m \cdot t_{\text{aus},t}^m$
l_t	während t geladene Energie [kWh]
e_t	während t entladene Energie [kWh]

Tabelle 4.2: Entscheidungsvariablen des Optimierungsmodells mit Einheiten in eckigen Klammern

stellen sicher, dass nur einmal im zulässigen Zeitraum eingeschaltet wird, während¹

$$\sum_{k < T_{\text{ein},\min}^n} s_k^n + \sum_{k > T_{\text{aus},\max}^n - d_n} s_k^n = 0, \forall n \in N \quad (4.3)$$

garantieren, dass nicht zu früh oder zu spät geschaltet wird. Schließlich sorgen

$$v_t^n - \sum_{k=1}^{\max(t, d_n)} \pi_k^n \cdot s_{t-k+1}^n = 0, \forall n \in N, t \in \{1, \dots, T\} \quad (4.4)$$

dafür, dass der Verbrauch von Anwendung n während der d_n Zeitfenster nach dem Einschalten genau den Werten von Π^n und sonst 0 gleicht.

Anwendungen, die bereits in der Vergangenheit gestartet wurden und in den aktuellen Optimierungshorizont hinein weiterlaufen, werden in der Prognose für den akkumulierten Verbrauch aller festen Lasten f_t für $t \in \{1, \dots, T\}$ berücksichtigt.

¹hier gilt die Konvention, dass die leere Summe den Wert 0 hat

4.1.3 Unterbrechbare Lasten

Eine Anwendung m aus der Kategorie M der unterbrechbaren Lasten kann in jedem Zeitfenster ein- oder ausgeschaltet werden, solange

- (i) sie nach dem Ausschalten mindestens $\underline{T}_{\text{aus}}^m$ Zeitfenster still steht,
- (ii) nach dem Einschalten mindestens $\underline{T}_{\text{ein}}^m$ Zeitfenster durchläuft,
- (iii) mindestens während \underline{T}^m Zeitfenstern läuft und
- (iv) insgesamt höchstens \bar{S}^m mal ein- und ausgeschaltet wird.

Die Leistung während eines Zeitfensters t wird auch hier als konstant null oder P^m angenommen.

Um obige Anforderungen im Modell zu berücksichtigen werden pro Anwendung m und Zeitfenster t die fünf Entscheidungsvariablen z_t^m , e_t^m , a_t^m , $t_{\text{ein},t}^m$ und $t_{\text{aus},t}^m$ verwendet. Dabei sind die ersten drei binär: z_t^m modelliert den Zustand der Anwendung m zum Zeitpunkt t , ist also gleich 1 wenn diese läuft und 0 wenn sie still steht. e_t^m und a_t^m bilden das Ein- beziehungsweise Ausschalten von m ab und sind analog zu (4.1) definiert.

Die Nebenbedingungen

$$z_t^m - z_{t-1}^m - e_t^m + a_t^m = 0, \forall m \in M, t \in \{1, \dots, T\}, \quad (4.5)$$

$$e_t^m + a_t^m \leq 1, \forall m \in M, t \in \{1, \dots, T\} \quad (4.6)$$

regeln die Beziehung zwischen Zustand, Ein- und Ausschalten, wobei z_0^m ein Parameter und keine Entscheidungsvariable ist. Dieser muss allerdings nicht gesondert an die Optimierung übergeben werden, sondern ergibt sich aus dem Vorzeichen des im Folgenden erläuterten Wertes $t_{\text{ein},0}^m$.

Zur Einhaltung der Mindestlauf- und Mindeststandzeiten werden die kontinuierlichen Variablen $t_{\text{ein},t}^m$ und $t_{\text{aus},t}^m$ benötigt, die die Dauer der Lauf- und Standzeiten darstellen. Für letztere ergeben sich

$$t_{\text{ein},t}^m = (t_{\text{ein},t-1}^m + 1) \cdot z_{t-1}^m \quad (4.7)$$

beziehungsweise

$$t_{\text{aus},t}^m = (t_{\text{aus},t-1}^m + 1) \cdot (1 - z_{t-1}^m) \quad (4.8)$$

4 Optimierungsmodell

und damit nichtlineare Nebenbedingungen. Diese zu umgehen hilft folgendes

Lemma 4.1 *Produkte der Form*

$$y = x \cdot \delta \tag{4.9}$$

mit einer ² Binärvariable δ und einer kontinuierlichen nichtnegativen Variable x sowie einer oberen Schranke X von x , können durch die Ungleichungen

$$y \geq 0, \tag{4.10}$$

$$y \leq \delta \cdot X, \tag{4.11}$$

$$y \leq x, \tag{4.12}$$

$$y \geq x - X \cdot (1 - \delta), \tag{4.13}$$

dargestellt werden.

Beweis: Die Äquivalenz wird in zwei Schritten gezeigt:

- (4.9) \Rightarrow (4.10)-(4.13): Ungleichung (4.10) folgt unmittelbar aus der Nichtnegativität von x und δ . Für die übrigen werden zwei Fälle unterschieden:
 - Gilt $y = x \cdot \delta = 0$, so sind (4.11) und (4.12) trivialerweise erfüllt. Außerdem muss x oder δ gleich 0 sein. So erhält man, dass

$$x - X \cdot (1 - \delta) = \begin{cases} x - X, & \text{falls } x > 0 \text{ und } \delta = 0, \\ 0, & \text{falls } x = 0 \text{ und } \delta > 0, \\ -X, & \text{falls } x = 0 \text{ und } \delta = 0 \end{cases}.$$

In jedem Fall gilt also $x - X \cdot (1 - \delta) \leq 0 = y$ und somit (4.13).

- Bei $y = x \cdot \delta > 0$ muss $\delta = 1$ und daher $y = x$ gelten. Einsetzen dieser Erkenntnisse in (4.10)-(4.13) zeigt, dass alle Ungleichungen erfüllt sind.
- (4.9) \Leftarrow (4.10)-(4.13): Es werden wieder zwei Fälle unterschieden:

²in[7] wird dieses Lemma sogar für das Produkt aus endlich vielen Binärvariablen und einer kontinuierlichen, oder ganzzahligen nichtnegativen Variable gezeigt

4.1 Deterministisches Optimierungsmodell

- Gilt $y = 0$, so folgt aus (4.13), dass $x \leq X \cdot (1 - \delta)$ sein muss. Da diese Bedingung offensichtlich verletzt ist, wenn sowohl x als auch δ positiv ist, erhält man $x \cdot \delta = 0 = y$.
- Bei $y > 0$ zeigt (4.11), dass $\delta = 1$ ist. Weiters liefert (4.13) $y \geq x$ und (4.12) schließlich $y = x = x \cdot \delta$.

□

Für jedes $m \in M$ und $t \in \{1, \dots, T-1\}$ werden also Hilfsvariablen $g_t^m := z_t^m \cdot t_{\text{ein},t}^m$ und $h_t^m := z_t^m \cdot t_{\text{aus},t}^m$ benötigt um (4.7) und (4.8) durch die linearen Nebenbedingungen

$$t_{\text{ein},t+1}^m - g_t^m - z_t^m = 0 \quad (4.14)$$

$$-g_t^m \leq 0 \quad (4.15)$$

$$g_t^m - X \cdot z_t^m \leq 0 \quad (4.16)$$

$$g_t^m - t_{\text{ein},t}^m \leq 0 \quad (4.17)$$

$$t_{\text{ein},t}^m + X \cdot z_t^m - g_t^m \leq X \quad (4.18)$$

sowie

$$t_{\text{aus},t+1}^m + h_t^m - t_{\text{aus},t}^m + z_t^m = 1 \quad (4.19)$$

$$-h_t^m \leq 0 \quad (4.20)$$

$$h_t^m - X \cdot z_t^m \leq 0 \quad (4.21)$$

$$h_t^m - t_{\text{aus},t}^m \leq 0 \quad (4.22)$$

$$t_{\text{aus},t}^m + X \cdot z_t^m - g_t^m \leq X \quad (4.23)$$

zu ersetzen. Eine mögliche obere Schranke, die für sämtliche Nebenbedingungen hinreichend groß ist, wäre zum Beispiel

$$X := T + \max_{m \in M} \underline{T}_{\text{ein}}^m + \max_{m \in M} \underline{T}_{\text{aus}}^m.$$

Anforderungen (i) und (ii) können nun mit den Nebenbedingungen für alle $m \in M, t \in \{1, \dots, T-1\}$ und $k \in \{t+1, \dots, t + \min(\underline{T}_{\text{ein}}^m - 1, T - k)\}$

$$-z_t^m + e_k^m \leq 0 \quad (4.24)$$

4 Optimierungsmodell

beziehungsweise für alle $m \in M$, $t \in \{1, \dots, T-1\}$ und $k \in \{t+1, \dots, t + \min(\underline{T}_{\text{aus}}^m - 1, T - k)\}$

$$z_t^m + a_k^m \leq 1 \quad (4.25)$$

in das Modell übernommen werden.

Um zusätzlich die Anzahl der Zeitfenster, während denen die Anwendung zu Beginn der Optimierung bereits gelaufen oder gestanden ist, zu berücksichtigen, werden für jedes $m \in M$ außerdem je nach den Werten von $t_{\text{ein},0}^m$ und $t_{\text{aus},0}^m$ weitere Ungleichungen benötigt. Für den Fall, dass $t_{\text{ein},0}^m > 0$ gilt, sind das

$$-z_k^m \leq -1, \forall m \in M, k \in \{1, \dots, \underline{T}_{\text{ein}}^m - \min(t_{\text{ein},0}^m, \underline{T}_{\text{ein}}^m)\} \quad (4.26)$$

bei $t_{\text{aus},0}^m > 0$ hingegen

$$z_k^m \leq 0, \forall m \in M, k \in \{1, \dots, \underline{T}_{\text{aus}}^m - \min(t_{\text{aus},0}^m, \underline{T}_{\text{aus}}^m)\}. \quad (4.27)$$

Anforderung (iii) und (iv) können mit den Ungleichungen

$$\sum_{k=1}^T z_k^m \geq \underline{T}^m, \forall m \in M, \quad (4.28)$$

$$\sum_{k=1}^T e_k^m + a_k^m \leq \bar{S}^m \quad (4.29)$$

in der Optimierung berücksichtigt werden.

Bemerkung 4.1 Die Bedingung eine Anwendung m mindestens während \underline{T}^m Zeitfenstern laufen zu lassen ist bewusst allgemein formuliert. In der Praxis kann diese leicht ersetzt werden, bei einem Heiz- oder Kühlgerät könnte es zum Beispiel ein Temperaturintervall sein, das mittels einer thermischen Energiebilanz in das Optimierungsmodell integriert wird.

4.1.4 Stationärer Stromspeicher

Der stationäre Stromspeicher ermöglicht sowohl die Erhöhung des Eigenverbrauchs durch Zwischenspeichern des lokal erzeugten Stroms als auch den Bezug von Strom aus dem Netz zu Zeiten niedriger Preise und niedrigem Verbrauchs. Limitierende Faktoren, vor allem für den letztgenannten Fall, sind dabei der Wirkungsgrade für Laden und Entladen w_l und w_e . Diese werden erst im nächsten Unterabschnitt in Form eines um den Faktor $\frac{1}{w_l}$ erhöhten Strombedarfs beim Laden und einer um den Faktor w_e verringerten Stromausbeute beim entladen berücksichtigt.

Um den Speicher in der Optimierung berücksichtigen zu können, werden für jedes $t \in \{1, \dots, T\}$ die beiden kontinuierlichen Entscheidungsvariablen l_t und e_t benötigt, die die geladene und die entladene Energie während des jeweiligen Zeitfensters repräsentieren. Auch hier gilt die Annahme, dass die Lade- und Entladeleistung während jedes Zeitfensters konstant bleiben.

Für jedes $t \in \{1, \dots, T\}$ stellen die Bedingungen

$$\sum_{k=1}^t (l_k - e_k) \leq \bar{B} - B_0 \quad (4.30)$$

sowie

$$\sum_{k=1}^t (-l_k + e_k) \leq -\underline{B} + B_0 \quad (4.31)$$

sicher, dass der stationäre Stromspeicher nur bis zu zulässigen Werten gelad und entladen wird.

Weiters sorgen die Ungleichungen

$$l_t \leq l_{\max}, \quad (4.32)$$

$$-l_t \leq 0, \quad (4.33)$$

$$e_t \leq e_{\max} \quad (4.34)$$

und

$$-e_t \leq 0 \quad (4.35)$$

4 Optimierungsmodell

für jedes $t \in \{1, \dots, T\}$ dafür, dass die ge- und entladene Energiemenge in jedem Zeitfenster im Intervall $[0, l_{\max}]$ beziehungsweise $[0, e_{\max}]$ liegt.

Eine zusätzliche Nebenbedingung die sicherstellt, dass zu jedem Zeitpunkt nur ge- oder entladen werden kann ist nicht notwendig, da bereits die Verluste $1 - w_l$ und $1 - w_e$ einen sinnvollen Betrieb des stationären Stromspeichers garantieren.

4.1.5 Erzeugungsanlage und Stromnetz

Neben den einzelnen Lasten gibt es auch auf Anlagenebene Kriterien, die es zu erfüllen gilt. So muss in jedem Zeitfenster

- die Summe aus Eigenverbrauch und Netzeinspeisung der Erzeugung gleichen,
- die Summe aus Eigenverbrauch und Netzbezug dem Gesamtverbrauch gleichen und
- der Netzbezug stets unter dem Maximalwert liegen.

Es werden also für jedes $t \in \{1, \dots, T\}$ Variablen ϕ_t für den Eigenverbrauch, η_t für die Netzeinspeisung und β_t für den Netzbezug gebraucht, die die Nebenbedingungen

$$\phi_t + \eta_t = g_t, \quad (4.36)$$

$$\phi_t + \beta_t = \sum_{n \in N} v_t^n + \sum_{m \in M} z_t^m \cdot P^m + \frac{1}{w_l} \cdot l - w_e \cdot e + f_t \quad (4.37)$$

und

$$\beta_t \leq P_{\max} \quad (4.38)$$

zu erfüllen haben.

4.1.6 Zielfunktion

Das Ziel ist Netzeinspeisung und -bezug so zu wählen, dass die Kosten minimal sind. Dabei sind die in den vorangegangenen Abschnitten dieses Kapitels erarbeiteten Nebenbedingungen einzuhalten.

4.2 Anwendung des zweistufigen Optimierungsmodelles in der Praxis

So ergibt sich insgesamt folgendes gemischt-ganzzahliges, lineares Programm

$$\min_{\mathbf{f}, \mathbf{j}} \quad \sum_{t=1}^T p_t \cdot \beta_t - \sum_{t=1}^T q_t \cdot \eta_t \quad (4.39)$$

$$\text{u.B.v. } (4.2) - (4.6), (4.14) - (4.38). \quad (4.40)$$

4.2 Anwendung des zweistufigen Optimierungsmodelles in der Praxis

Das hier entwickelte deterministische Modell wird nun mit dem Prognosemodell aus dem vorigen Kapitel zu einem zweistufigen Verfahren zusammengeschlossen.

Am Anfang eines jeden Zeitfensters wird dabei zunächst durch das künstliche neuronale Netz eine Prognose für den Verbrauch der nicht verschiebbaren Lasten über den Optimierungshorizont erstellt. Letzterer ist aufgrund der Tatsache, dass die Strompreise für den Folgetag um 14:00 Uhr veröffentlicht werden, zu jeder Tageszeit ein anderer und liegt zwischen 11 und 34 Stunden. Konkret sieht der Horizont wie folgt aus³

$$\begin{array}{rcl} 14 \text{ Uhr (34 Stunden)} : & 15 & 16 & 17 & \dots & 38 & \dots & 48 \\ 15 \text{ Uhr (33 Stunden)} : & & 16 & 17 & \dots & 38 & \dots & 48 \\ 16 \text{ Uhr (32 Stunden)} : & & & 17 & \dots & 38 & \dots & 48 \\ & & & \vdots & & \vdots & & \vdots \\ 13 \text{ Uhr (11 Stunden)} : & & & & & 38 & \dots & 48 \end{array} \quad (4.41)$$

Außerdem muss vor jedem Optimierungsaufwurf überprüft werden, welche verschiebbare Lasten mit festem Profil frühest mögliche Startzeit und spätest mögliche Endzeit innerhalb des Horizontes haben.

³Die Zahl j bezeichnet dabei die j -te Stunde des Zeitraumes von 0 Uhr des ersten Tages bis 24 Uhr des zweiten Tages. 15 ist also die Zeit von 14 Uhr bis 15 Uhr, 48 die Zeit von 23 Uhr bis 24 Uhr

5 Fallstudien - Ausgangslage

Abschließend soll das zweistufige stochastische Optimierungsmodell anhand realer Verbrauchs-, Erzeugungs- und Preisdaten getestet und dessen (betriebswirtschaftlicher) Nutzen bewertet werden.

Zu diesem Zweck werden zunächst die Herkunft der erforderlichen Daten und die Modellierungssoftware erläutert. Anschließend werden verschiedene Architekturen von künstlichen neuronalen Netzen beschrieben und deren Performance verglichen.

5.1 Datengrundlage

Verbrauchs-, Erzeugungs- und Preisdaten wurden den nachfolgenden Quellen entnommen.

5.1.1 Verbrauchsprofile

Um die Stärken von künstlichen neuronalen Netzen zur Prognose von Zeitreihen ausführlich zu erörtern, werden drei unterschiedliche Lastprofile für die Simulationen herangezogen:

- der Verbrauch eines Bürohauses inklusive Heiz- und Kühlsystem,
- der Lastgang eines Einfamilienhauses, sowie
- das Profil eines Gastronomiebetriebes.

5 Fallstudien - Ausgangslage

Bürohaus

Dieses Lastprofil wurde bei einem Bürohaus inklusive Heiz- und Kühlsystem in Niederösterreich zwischen August und Juni gemessen. Zur Wahrung der Anonymität des Betreibers wurde der Verbrauch in diesem Zeitraum auf 100 000 kWh normiert.

Abbildung 5.1 zeigt den gesamten Verlauf, während Abbildung 5.2 zwei Wochen etwas genauer zeigt.

Bei Betrachtung dieses Profiles sind einige charakteristische Eigenschaften ersichtlich, vor allem

- das recht klare Muster, das speziell in Abbildung 5.2 zu erkennen ist,
- die starke Abhängigkeit des Verbrauchs vom Wochentag sowie
- eine ausgeprägte saisonale Schwankung.

Vor allem der erste Punkt sollte die Prognose erleichtern, während die anderen beiden Dinge eine gewisse Anpassung der Prognose erfordern.

Einfamilienhaus

Das Haushaltslastprofil stammt aus [10] und ist in den Abbildungen 5.3 und 5.4 dargestellt.

Hier fällt im Gegensatz zum Profil des Bürohauses auf, dass

- kein klares Muster zu erkennen ist,
- der Verbrauch auch nicht sonderlich stark vom Wochentag abhängt und
- die Jahreszeit kaum Einfluss zu haben scheint.

Gastronomiebetrieb

Dieses Lastprofil wurde bei einem Gastronomiebetrieb in Niederösterreich zwischen Jänner und Dezember gemessen. Zur Wahrung der Anonymität des Betreibers wurde der Verbrauch in diesem Zeitraum auf 100 000 kWh normiert.

5.1 Datengrundlage




Abbildung 5.1: Verbrauchsprofil des Bürohauses von August bis Juni mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate




Abbildung 5.2: Verbrauchsprofil des Bürohauses für zwei Wochen im August mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate

5 Fallstudien - Ausgangslage




Abbildung 5.3: Verbrauchsprofil des Haushalts von Jänner bis Dezember mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate




Abbildung 5.4: Verbrauchsprofil des Haushalts für zwei Wochen im August mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate

Abbildung 5.5 zeigt den gesamten Verlauf, während Abbildung 5.6 zwei Wochen etwas genauer zeigt.

Dieses Profil vereint Eigenschaften der beiden vorigen:

- Ein Muster ist zu erkennen,
- der Verbrauch hängt nicht sonderlich stark vom Wochentag ab,
- die Jahreszeit hat kaum Einfluss.

5.1.2 Flexible Lasten

Für die Fallstudien werden folgende flexible Lasten betrachtet:

- ein Wäschetrockner, der zur Klasse der verschiebbaren Lasten mit festem Profil zählt. In den ersten drei Stunden wird die Wäsche gewaschen und 1,06 kWh werden verbraucht, in den nächsten drei Stunden wird getrocknet bei einem Verbrauch von 2,82 kWh, siehe [15]. Das stündliche Verbrauchsprofil in kWh ist also (0,35;0,35;0,35;0,94;0,94;0,94).
- ein Geschirrspüler, der ebenfalls zur Klasse der verschiebbaren Lasten mit festem Profil zählt und in drei Stunden 1,02 kWh verbraucht, siehe [20]. Das stündliche Verbrauchsprofil in kWh lautet demnach (0,34;0,34;0,34).
- eine Wärmepumpe, aus der Klasse der unterbrechbaren Lasten. Diese hat eine elektrische Leistung von 2,2 kW, siehe [18]. Zur Verbesserung von Lebensdauer und Wirkungsgrad, muss sie nach dem Einschalten 3 Stunden durchlaufen und nach dem Ausschalten 2 Stunden stillstehen.
- eine Batterie mit Wirkungsgrad von je 96 Prozent beim Laden und Entladen und einem nutzbaren Bereich von 20 bis 100 Prozent, in den Ausführungen
 - klein mit einer Kapazität von 4,5 kWh, Lade- und Entladeleistung von 2,4 kW sowie
 - groß mit einer Kapazität von 12 kWh, Lade- und Entladeleistung von 6,4 kW,

siehe [17].

5 Fallstudien - Ausgangslage




Abbildung 5.5: Verbrauchsprofil des Gastronomiebetriebs von Jänner bis Dezember mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate




Abbildung 5.6: Verbrauchsprofil des Gastronomiebetriebs für zwei Wochen im August mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate

5.1.3 Erzeugungsprofil - Photovoltaik

Die Stadtgemeinde Pressbaum hat seit August 2009 eine Photovoltaikanlage und veröffentlicht den Ertrag seit Ende März 2012 online, siehe 21. Die Spezifikationen sind in Tabelle 5.1 aufgelistet

Standortdaten	
Anlagen-ID:	LUFK1
Name der Anlage:	Stadtgemeinde Pressbaum
Längengrad:	16.5520774
Breitengrad:	48.2995998
Höhe über NN:	155 m
Straße:	Hauptstraße 58
Ort:	Pressbaum
Zeitzone:	Europa/Wien
Technische Daten	
Leistung:	5,05 kWp
Fläche:	30.26 m ²
Nachführung:	keine
Neigung:	18°
Ausrichtung:	180°
Montageart:	Aufdachanlage, Abstand < 10 cm
Inbetriebnahme	25.08.2009
Wechselrichtertyp:	Fronius IG 60
Anzahl Wechselrichter:	1
Modultyp:	Sanyo HIP-210NKHE1
Anzahl Module:	24

Tabelle 5.1: Spezifikationen der Photovoltaikanlage laut 21

Das hier verwendete Erzeugungsprofil stammt aus dem Jahr 2013.

5.1.4 Strompreis

Der Strompreis setzt sich aus den drei Komponenten Arbeitspreis, Netzgebühren sowie Steuern und Abgaben zusammen, wobei sämtliche Werte als

5 Fallstudien - Ausgangslage

Nettopreise zu verstehen sind. Insgesamt sind folgende verbrauchsabhängige Posten zu berücksichtigen, siehe [13], [14] und [19]:

- **Arbeitspreis:** Die Firma aWATTar bietet einen stündlich-variablen Stromtarif an. Dabei wird der Preis des Spotmarkts EPEXSPOT der European Energy Exchange (EEX) direkt an den Kunden weitergegeben. Konkret handelt es sich dabei um den PHELIX Day-Ahead Hour Block. Darauf werden noch 0,1 Cent pro kWh für Ökostromzertifikate, sowie eine Grundpauschale geschlagen. Letztere wird wie alle Fixkosten in dieser Arbeit allerdings nicht berücksichtigt, da sie als Konstante Verschiebung keinen Einfluss auf das Ergebnis der Optimierung hat.
- **Netzgebühren:** Diese setzen sich in Niederösterreich für die Netzebene 7 ohne Leistungsmessung zusammen aus:
 - 4,51 Cent/kWh Netznutzungsentgelt
 - 1,159 Cent/kWh Ökostromförderbeitrag Netznutzung
 - 0,149 Cent/kWh Netzverlustentgelt
 - 0,053 Cent/kWh Ökostromförderbeitrag Netzverlust
- **Steuern und Abgaben:** 1,5 Cent/kWh Elektrizitätsabgabe

Für die Einspeisung wird der Tarif SUNNY von aWATTar ohne Netzgebühren und Abgaben vergütet. Dieser ist jeweils für einen Monat konstant, siehe [14].

5.2 Modellierungssoftware

Als Umgebung für die Implementierung des Modells sowie für die Durchführung der Simulationen wurde MATLAB in der Version R2013b verwendet.

Für die gemischt-ganzzahlige Optimierung wurde zusätzlich der Solver Gurobi in der Version 6.5.1 hinzugezogen.

5.3 Performancevergleich verschiedener künstlicher neuronaler Netze

Im Kapitel über künstliche neuronale Netze wurde erklärt wie ein solches Prognosen für Zeitreihen liefern kann, ohne jedoch im Detail festzulegen wie dieses aufgebaut sein muss. Um eine für die Prognose von Stromverbräuchen geeignete Architektur zu ermitteln werden in diesem Abschnitt verschiedene Möglichkeiten anhand der drei bereitgestellten Lastprofile bewertet. Dabei wird jeweils das erste Halbjahr, also die ersten 4380 Stunden für die Lernphase verwendet. Für das zweite Halbjahr wird dann stündlich eine Prognose mit einem Horizont von 24 erstellt und der Mean Absolute Percentage Error (MAPE), also

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{T_t - P_t}{T_t} \right|, \quad (5.1)$$

berechnet, wobei P_t den prognostizierten und T_t den tatsächlichen Wert für die t -te Stunde bezeichnet. Der Durchschnitt über die Fehler aller Prognosen wird dann als Performance-Maß angewandt.

Während die Anzahl der Neuronen in der Ausgangsschicht mit 1 vorgegeben ist, kann die Stärke der versteckten Schichte sowie der Neuronen in diesen und der Eingangsschicht grundsätzlich beliebig sein.

Die Gestalt der Eingangsschicht entscheidet darüber, wie viele historische Werte für die Prognose berücksichtigt werden. Hier hat sich ein voller Tag, also 24 Stunden, als Kompromiss zwischen Genauigkeit und Rechenaufwand gut bewährt.

Bezüglich Anzahl und Stärke der versteckten Schichten gibt es in der Literatur deutlich von einander abweichende Empfehlungen, in [8] auf Seite 37 sind einige davon aufgelistet. Es wird allerdings auch in jeder Quelle darauf hingewiesen, dass der optimale Aufbau stark von der konkreten Anwendung abhängt und durch probieren ermittelt werden muss

Daher werden in diesem Abschnitt folgende Architekturen verglichen:

- NN1: 24 Neuronen¹ in der Eingangsschicht, eine versteckte Schicht mit 12 Neuronen, 1 Neuron in der Ausgangsschicht,

¹für die letzten 24 Werte

5 Fallstudien - Ausgangslage

- NN2: 24 Neuronen in der Eingangsschicht, zwei versteckte Schichten, die erste mit 24, die zweite mit 12 Neuronen, 1 Neuron in der Ausgangsschicht.

Um dem Anspruch gerecht zu werden, ein robustes und möglichst universell einsetzbares Prognose-Tool zu erstellen, werden auch Netze untersucht, die neben den 24 letzten Verbrauchswerten zusätzlich den Durchschnittsverbrauch der letzten 4 Wochen über die vorherzusagende Stunde desselben Wochentages als Eingangswert haben. Soll also der Verbrauch für Dienstag von 21 bis 22 Uhr prognostiziert werden, bekommt das künstliche neuronale Netz auch den Durchschnittsverbrauch der letzten vier Dienstage von 21 bis 22 Uhr als Eingabe. Das soll dazu führen, dass Muster besser erkannt werden, ohne aufwändige Analysen der Unterschiede zwischen den einzelnen Tagen.

Daher werden zusätzlich folgende Architekturen untersucht:

- NN3: 25 Neuronen² in der Eingangsschicht, eine versteckte Schicht mit 12 Neuronen, 1 Neuron in der Ausgangsschicht
- NN4: 25 Neuronen in der Eingangsschicht, zwei versteckte Schichten, die erste mit 24, die zweite mit 12 Neuronen, 1 Neuron in der Ausgangsschicht.

Als Referenz dient die Prognose eines linearen Regressionsmodells, das mit LR bezeichnet wird.

Bemerkung 5.1 *Ein großer Vorteil von künstlichen neuronalen Netzen ist die Fähigkeit verschiedene Arten von Eingangswerten zu verarbeiten. So könnten in der Praxis ohne aufwändige Änderungen zusätzliche Parameter wie Außentemperatur oder Sonneneinstrahlung übergeben werden.*

Performance Bürohaus

Abbildungen 5.7 zeigt exemplarisch den tatsächlichen Verbrauch sowie die unterschiedlichen Prognosen für einen Horizont von Freitag Abend bis Samstag Abend. Hier sind die beiden Netze NN3 und NN4 klar im Vorteil, da

²für die letzten 24 Werte plus den Durchschnittswert der letzten vier Wochen zu jener Stunde

5.3 Performancevergleich verschiedener künstlicher neuronaler Netze

sie durch die Zugabe des Durchschnittswertes der jeweiligen Stunde über die letzten Wochen erkennen, dass der Verbrauch am Samstag nicht wie am Freitag nach oben geht.

Berechnet man den durchschnittlichen Mean Absolute Percentage Error aller stündlichen Prognosen mit 24-stündigem Horizont zwischen Februar und Juni, erkennt man, dass die künstlichen neuronalen Netze an sich nicht wesentlich besser abschneiden als die deutlich einfachere lineare Regression, siehe Abbildung 5.8. Sehr wohl eine Verbesserung bewirkt allerdings der Durchschnitt als zusätzlicher Eingangswert.

Allgemein sind die Fehler bei diesem Profil gering.

Performance Einfamilienhaus

Hier zeigt sich ein anderes Bild. Wie in Abbildungen 5.9 zu sehen ist, kommen die künstlichen neuronalen Netze mit chaotischen Profil deutlich besser zurecht, als die lineare Regression, die hier viel zu träge ist.

Der Mean Absolute Percentage Error aller stündlichen Prognosen mit 24-stündigem Horizont zwischen Juli und Dezember aus Abbildung 5.10 bestätigt, dass die komplexere Architekturen mit mehr Schichten und Neuronen vorteilhaft für ein Profil ohne klares Muster sind. Der Durchschnitt als 25. Eingangswert allein scheint hingegen nicht zwingend zu einer deutlichen Reduktion des Fehlers zu führen.

Der Fehler ist zudem hoch, das Profil also anspruchsvoll zu prognostizieren.

Performance Gastronomiebetrieb

Bei der Prognose des Verbrauchs des Gastronomiebetriebs haben die künstlichen neuronalen Netze eine bessere Performance als die lineare Regression, die auch hier zu glatt vorhersagt. Die vier Architekturen haben über einen längeren Zeitraum aber annähernd den gleichen Fehler.

5 Fallstudien - Ausgangslage




Abbildung 5.7: Vergleich der Prognosen für den Verbrauch des Bürohauses an einem Tag mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate




Abbildung 5.8: Mittlerer MAPE für die stündlichen Prognosen für den Verbrauch des Bürohauses von Februar bis Juni mit Horizont 24 Stunden

5.3 Performancevergleich verschiedener künstlicher neuronaler Netze




Abbildung 5.9: Vergleich der Prognosen für den Verbrauch des Haushaltes an einem Tag mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate




Abbildung 5.10: Mittlerer MAPE für die stündlichen Prognosen für den Verbrauch des Haushaltes von Juli bis Dezember mit Horizont 24 Stunden

5 Fallstudien - Ausgangslage




Abbildung 5.11: Vergleich der Prognosen für den Verbrauch des Gastronomiebetriebs an einem Tag mit Zeit in Stunden auf der Abszisse und Leistung in kW auf der Ordinate




Abbildung 5.12: Mittlerer MAPE für die stündlichen Prognosen für den Verbrauch des Gastronomiebetriebs von Juli bis Dezember mit Horizont 24 Stunden

5.3 Performancevergleich verschiedener künstlicher neuronaler Netze

Fazit

Trotz unterschiedlicher Charakteristiken konnte sich NN₄ das komplexeste künstliche neuronale Netz, bei allen drei Verbrauchsprofilen behaupten. Daher wird dieses auch für die Fallstudien verwendet.

6 Fallstudien - Ergebnisse

In diesem Kapitel werden für unterschiedliche Konfigurationen Simulationen für eine Woche ausgewertet. Dabei wird zu jeder Stunde eine zweistufige Optimierung mit Horizont laut (4.41) durchgeführt und die Ergebnisse der ersten Periode implementiert. Danach wiederholt sich dieser Vorgang.

Als Vergleichswert dient ein Szenario, in dem der Benutzer jede Anwendung sofort einschaltet, also zum Beginn des möglichen Zeitfensters, die Wärmepumpe ab 22 Uhr läuft und keine Batterie vorhanden ist.

6.1 Haushalt

Der Haushalt verfügt über folgende Ausstattung:

- ein Wäschetrockner, der einmal täglich zwischen 14 Uhr und 14 Uhr laufen muss,
- ein Geschirrspüler, der einmal täglich zwischen 18 Uhr und 8 Uhr laufen muss,
- ein Wärmepumpe, die täglich 8 Stunden laufen muss,
- eine kleine Batterie (4,5 kWh) sowie
- eine Photovoltaikanlage.

Ergebnisse mit Photovoltaikanlage

Abbildung 6.1 zeigt das Verhalten des Haushaltes während einer Woche. Der Optimierungsalgorithmus verschiebt die Lasten offensichtlich derart, dass primär der Eigenverbrauch erhöht wird. Darüber hinaus wird Strom aus dem

6 Fallstudien - Ergebnisse

Netz bezogen, wenn dieser günstig ist. Diese Priorisierung ist nicht überraschend, da beim Eigenverbrauch die Netzkosten und Abgaben gespart werden können, die deutlich höher sind als die Schwankungen des Strompreises.

Auf Abbildung 6.2 sind die Kosten für die Woche zu sehen. Das zweistufige Optimierungsmodell schafft es dabei einen Großteil der theoretisch möglichen Ersparnis im Falle perfekter Information zu realisieren.




Abbildung 6.1: Verhalten des Haushaltes mit Photovoltaikanlage über den Verlauf einer Woche

Ergebnisse ohne Photovoltaikanlage

Die Ergebnisse des Haushaltes mit Photovoltaikanlage haben gezeigt, dass die

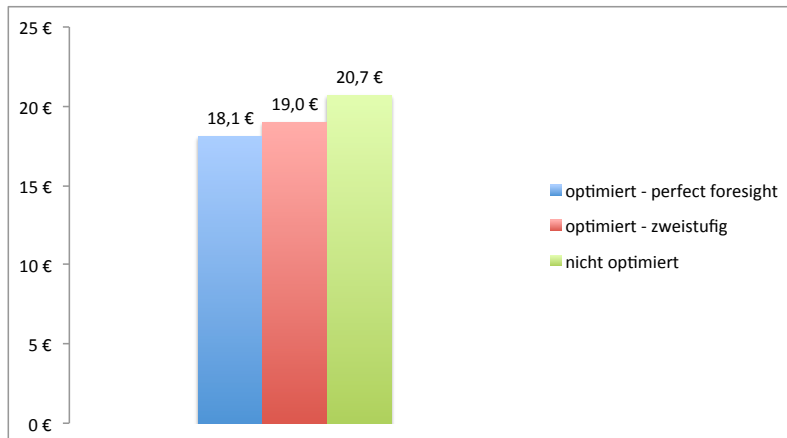


Abbildung 6.2: Kosten des Haushalts für eine Woche mit Photovoltaikanlage

Optimierung vorrangig den Eigenverbrauch maximiert. Um aufzuzeigen wie hoch das verbleibende Einsparpotential ist, falls der Strompreis die einzige Entscheidungsgrundlage ist, wird die Leistung der Photovoltaikanlage auf 0 gesetzt.

Abbildung 6.3 zeigt das Verhalten des Haushalts in diesem Fall.

Laut Abbildung 6.4 ist die mögliche Einsparung ohne Photovoltaikanlage ungefähr halb so groß.

6.2 Bürohaus

Das Bürohaus verfügt lediglich über

- eine Photovoltaikanlage, die sechs Anlagen aus dem vorigen Kapitel entspricht und
- zwei große Batterien (2 mal 12 kWh).

Abbildung 6.5 zeigt, wie die Batterien eingesetzt werden. Da der Verbrauch speziell am Tag hoch ist, wird ein großer Teil des Solarstroms ohnehin direkt verbraucht. Dementsprechend wenig wird die Batterie eingesetzt. Das Einsparpotential durch die Schwankungen im Strompreis ist gering, da die

6 Fallstudien - Ergebnisse




Abbildung 6.3: Verhalten des Haushaltes ohne Photovoltaikanlage über den Verlauf einer Woche

6.2 Bürohaus

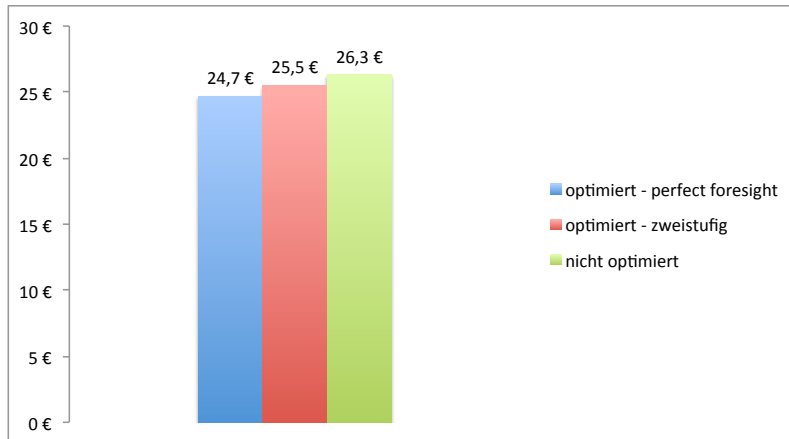


Abbildung 6.4: Kosten des Haushalts für eine Woche ohne Photovoltaikanlage




Abbildung 6.5: Verhalten des Bürohauses über den Verlauf einer Woche

6 Fallstudien - Ergebnisse

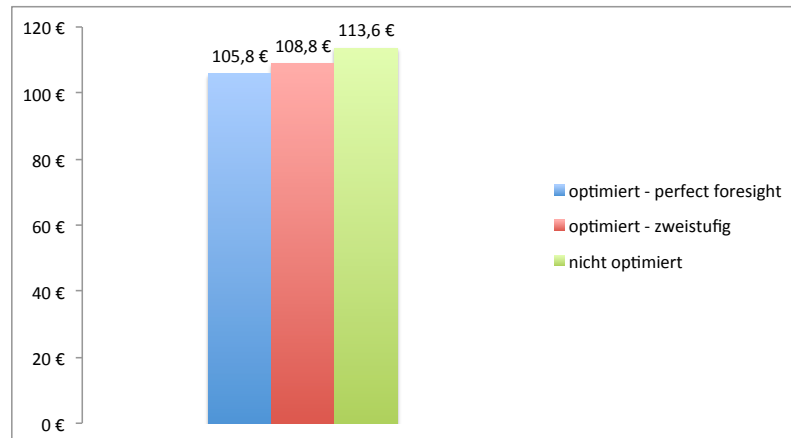


Abbildung 6.6: Kosten des Bürohauses für eine Woche

Verluste beim Be- und Entladen nicht immer wirtschaftlich ausgeglichen werden können.

Die relative Ersparnis in Abbildung 6.6 ist geringer als beim Haushalt, was nicht überrascht, da es außer dem Speicher keine flexiblen Lasten gibt.

6.3 Gastronomiebetrieb

Der Gastronomiebetrieb verfügt wie das Bürohaus über

- eine Photovoltaikanlage, die sechs Anlagen dem vorigen Kapitel entspricht und
- zwei große Batterien (2 mal 12 kWh).

Abbildung 6.7 zeigt für den Gastronomiebetrieb ein ähnliches Bild wie für das Bürohaus, die Batterien werden aus denselben Gründen nur spärlich eingesetzt.

Die relative Ersparnis in Abbildung 6.8 ist auch hier geringer als beim Haushalt.

6.3 Gastronomiebetrieb




Abbildung 6.7: Verhalten des Gastronomiebetriebs über den Verlauf einer Woche

6 Fallstudien - Ergebnisse




Abbildung 6.8: Kosten des Gastronomiebetriebs für eine Woche

7 Schlussfolgerungen

Die künstlichen neuronale Netze, die den Durchschnitt der letzten Wochen als zusätzlichen Input übernehmen, haben sich tatsächlich als robuste und verlässliche Prognosemodelle bewiesen. Sie haben für alle drei Lastprofile den geringsten Fehler geliefert, wobei auch die Netze ohne Durchschnitt Vorteile gegenüber der linearen Regression haben. Diese sind dann am größten, wenn das vorherzusagende Lastprofil wenig Struktur hat, wie zum Beispiel bei einem Haushalt, während bei Verbräuchen mit hoher Regelmäßigkeit die lineare Regression ähnlich gute Ergebnisse liefert.

Das Optimierungsmodell zur Lastverschiebung bringt in allen Szenarien Ersparnisse.

Im Falle perfekter Information¹ liegt das Potential zwischen 12 und 4 Prozent der verbrauchsabhängigen Kosten. Der Haushalt, der über den größten Anteil flexibler Lasten verfügt, liegt dabei wenig überraschend am oberen Ende, während der Gastronomiebetrieb, der den Verbrauch nur mittels Batterie verlagern kann, weniger spart. Interessant ist zusätzlich, dass der Haushalt auch ohne Photovoltaikanlage seine Kosten durch Ausnutzen der Schwankungen im Strompreis um 6 Prozent senken kann.

Das zweistufige stochastische Optimierungsmodell zur Lastverschiebung realisiert in allen Szenarien etwa zwei Drittel der theoretisch möglichen Ersparnis im Falle perfekter Information. Dies unterstreicht die Wichtigkeit zuverlässiger Prognosen indem es zeigt, dass sich die Qualität der Vorhersage spürbar in den Kosten niederschlägt.

Insgesamt ist die Kostenreduktion auch deswegen überschaubar, weil die aktuelle Zusammensetzung des Strompreises wenig Anreiz zur Lastverlagerung

¹also für den Fall eines deterministischen Modells ohne Prognose

7 Schlussfolgerungen

gibt. Lediglich der Energiepreis schwankt in Abhängigkeit von Angebot und Nachfrage, Netzgebühren und Abgaben sind dagegen konstant.

Offene Fragen für weiterführende Untersuchungen beinhalten

- die Gegenüberstellung von Investitionskosten und daraus resultierende Ersparnisse, um in Form eines Barwertes Investitionsentscheidungen treffen zu können;
- die Auswirkungen einer Preisstruktur in der neben dem Energiepreis auch Netzgebühren und Abgaben monetäre Anreize zur Lastverlagerung liefern sowie
- die zusätzlichen Potentiale, die eine Optimierung ganzer Bilanzgruppen statt einzelner Kunden bringt.

Literatur

- [1] A. Barbato; A. Capone; G. Carello; M. Delfanti; M. Merlo; A. Zaminaga: *House Energy Demand Optimization in Single and Multi-User Scenarios*, Proceedings of the IEEE International Conference on Smart Grid Communications (Seiten 345-350), Brüssel, 2011
- [2] A. Barbato; A. Capone: *Optimization Models and Methods for Demand-Side Management of Residential Users: A Survey*, *Energies* 2014/7 (Seiten 5787-5824), 2014
- [3] S. Crone: *Neuronale Netze zur Prognose und Disposition im Handel*, Gabler, Wiesbaden, 2010
- [4] N. Farag Abed; M. Milosavljevic: *Single Home Electricity Power Consumption Forecast Using Neural Networks Model*, *IJISSET - International Journal of Innovative Science, Engineering and Technology*, Vol. 3 Issue 1, 2016
- [5] U. Gotzes: *Betriebsoptimierung eines Systems mit dezentralen Energieumwandlungsanlagen mittels gemischt-ganzzahliger linearer Modelle*, Universität Duisburg-Essen, 2005
- [6] K. Hornik; M. Stinchcombe; H. White: *Multilayer Feedforward Networks are Universal Approximators*, *Neural Networks* Vol. 2 (Seiten 359-366), 1989
- [7] J. Kallrath: *Gemischt-ganzzahlige Optimierung: Modellierung in der Praxis*, Springer, Wiesbaden, 2013
- [8] B. Ott: *Erstellung von Bedarfsprognosen durch Künstliche Neuronale Netze am Beispiel von Backmengenempfehlungen im Einzelhandel*, Hochschule für angewandte Wissenschaften Hamburg, 2013
- [9] D. Rubelhart; G. Hinton; R. Williams: *Learning Representations by Back-Propagating Errors*, *Nature* 323 (Seiten 533-536), 1986

Literatur

- [10] T. Tjaden, J. Bergner, J. Weniger, V. Quaschnig: *Repräsentative elektrische Lastprofile für Einfamilienhäuser in Deutschland auf 1-sekündiger Datenbasis*, , Datensatz, Hochschule für Technik und Wirtschaft HTW, Berlin, 2015
- [11] A. Veit; C. Goebel; R. Tidke; C. Doblander; H. Jacobsen: *Household Electricity Demand Forecasting – Benchmarking State-of-the-Art Methods*, Eprint arXiv:1040.0200, 2014
- [12] A. Zell: *Simulation neuronaler Netze*, Oldenburg, München, 2000
- [13] aWATTar, *Tarifblatt hourly*, <https://cdn.awattar.com/documents/legal/tariff-sheet/hourly.pdf> (abgerufen am 15.05.2017)
- [14] aWATTar, *Tarifblatt sunny*, <https://cdn.awattar.com/documents/legal/tariff-sheet/sunny.pdf> (abgerufen am 15.05.2017)
- [15] Bosch, *Waschtrockner WVG30442 - Gebrauchs- und Aufstellanleitung*, https://media3.bsh-group.com/Documents/9001053503_F.pdf (abgerufen am 15.05.2017)
- [16] E-Control, *Sonstige Marktregeln - Kapitel 10, Version 3.0, 2017*, https://www.e-control.at/documents/20903/388512/SoMa_10_V3.0.pdf/ec7doa2d-1527-5359-9739-5b8755368765 (abgerufen am 15.05.2017)
- [17] Fronius, *Technische Daten Fronius Energy Package*, https://www.fronius.com/cps/rde/xbcr/SID-FE9D22E2-27BF69EA/fronius_international/SE_DS_Fronius_Energy_Package_DE_386730_snapshot.pdf (abgerufen am 15.05.2017)
- [18] IDM, *Erdwärmepumpen TERRA SW - Produktblatt*, http://www.idm-energie.at/wp-content/uploads/2015/12/IDM_Produktblatt_Terra_SWComplete_2_Einzelseiten-1.pdf (abgerufen am 15.05.2017)
- [19] Netz Niederösterreich, *Informations- und Preisblatt Strom, Systemnutzungsentgelte, Förderbeiträge, Steuern und Abgaben*, [https://www.netz-noe.at/Download-\(1\)/Verteilernetzbedingungen-Strom/B410_Sytemnutzungstarife-Strom.aspx](https://www.netz-noe.at/Download-(1)/Verteilernetzbedingungen-Strom/B410_Sytemnutzungstarife-Strom.aspx) (abgerufen am 15.05.2017)

Literatur

- [20] Siemens, *SN514WooAE - Produktsteckbrief*, <https://products.bsh-partner.com/picenterext/specsheet/DE/de-DE/SN514WooAE.pdf> (abgerufen am 15.05.2017)
- [21] *Homepage der Stadtgemeinde Pressbaum*, <https://www.pressbaum.at> (abgerufen am 15.05.2017)