

# OPTIMIERUNG DER ENERGIEKOSTEN UND ANALYSE DER NETZUNTERSTÜTZUNG EINES GEBÄUDES MIT HILFE GENETISCHER PROGRAMMIERUNG UND SYMBOLISCHER REGRESSION

**Kathrin KEFER\*<sup>1</sup>, Roland HANGHOFER<sup>2</sup>, Patrick KEFER<sup>3</sup>, Markus STÖGER<sup>1</sup>, Bernd HOFER<sup>1</sup>, Michael AFFENZELLER<sup>2</sup>, Stephan WINKLER<sup>2</sup>**

<sup>1</sup> Fronius International GmbH, Günther-Fronius-Straße 1, 4600 Thalheim, +43 (7242) 241 1023, {kefer.kathrin-maria, stoeger.markus, hofer.bernd}@fronius.com

<sup>2</sup> FH Oberösterreich, Softwarepark11, 4232 Hagenberg, {roland.hanghofer, michael.affenzeller, stephan.winkler}@fh-hagenberg.at

<sup>3</sup> FH Oberösterreich, Ringstraße 43a, 4600 Wels, patrick.kefer@fh-wels.at

**Kurzfassung:** Auf Grund der vermehrten Verwendung von erneuerbaren Energiequellen vor allem im privaten Sektor ist deren effiziente und intelligente Nutzung nötig, um die Stabilität der Stromnetze nicht weiter zu belasten. Wegen der schwankenden und sich verändernden Rahmenbedingungen sind manche dieser Energiequellen zu bestimmten Tages- oder Jahreszeiten, wie eine Photovoltaik-Anlage bei Nacht, nicht oder nur eingeschränkt verfügbar, während sie zu anderen Zeiten starke Überschüsse produzieren. Dies hat teils große Auswirkungen auf das Stromnetz, welches mit einem starken Einspeiseüberschuss an Tagen mit viel Sonnenschein ebenso zurechtkommen muss, wie mit einem erhöhten Strombedarf bei Schlechtwetter oder abends. Energiemanagement Systeme stellen automatisierte Lösungen bereit, die die selbst produzierte Energie im Haushalt so optimal wie möglich verteilen, speichern und verbrauchen. Dadurch können etwaige Last- oder Erzeugungsspitzen abgeschwächt und starken Schwankungen im Stromnetz entgegengewirkt werden. Allerdings liefern die bisher existierenden Lösungen entweder keine optimalen Ergebnisse oder sind sehr rechenintensiv. Das Ziel dieser Arbeit ist es deshalb, eine selbst-lernende Regelung zu entwickeln, die die Energiekosten eines Haushaltes mit Photovoltaik-Anlage und Batteriespeicher minimiert, die Netzstabilität unterstützt und in Echtzeit ausgeführt werden kann. In der Evaluierung von insgesamt zehn heuristischen Reglern kann gezeigt werden, dass im Vergleich zu einem linearen modellprädiktiven Regler und einer Regel-basierten Eigenverbrauchsoptimierung die Menge an eingespeistem und vom Netz bezogenen Strom insgesamt stark reduziert werden konnte. Des Weiteren wird im Vergleich zum linearen modellprädiktiven Regler auch die maximale Netzbezugs- und Einspeiseleistung um bis zu 50% verringert.

**Keywords:** Energiemanagement, Energieflusssteuerung, Kostenoptimierung, Netzstabilität, genetische Algorithmen, Symbolische Regression, heuristische Optimierung

---

<sup>1</sup> Fronius International GmbH, Günther-Fronius-Straße 1, 4600 Thalheim, kefer.kathrin-maria@fronius.com

<sup>2</sup> FH Oberösterreich, Softwarepark11, 4232 Hagenberg, roland.hanghofer@fh-ooe.at

<sup>3</sup> FH Oberösterreich, Ringstraße 43a, 4600 Wels, patrick.kefer@fh-ooe.at

## 1 Einführung

Um die Energiewende voranzutreiben und fossile Energiequellen wie Erdöl oder Kohle abzulösen, wurden erneuerbare Energiequellen in den letzten Jahren immer wichtiger. Dafür wurde beispielsweise der Bau von Windparks und auch von Photovoltaik-Anlagen (*PV*-Anlagen) im industriellen, aber auch im privaten Umfeld stark vorangetrieben. [1] Diese Anlagen sind jedoch nicht in der Lage, durchgehend und konstant die gleiche Energiemenge zu liefern, da die Produktion von nicht beeinflussbaren Faktoren abhängt. Beispielsweise produziert eine *PV*-Anlage bei Schlechtwetter oder bei Nacht nur wenig bis gar keine Energie, während Windkraftanlagen bei Flaute oder Sturm ebenfalls keine Energie produzieren können. Der Zubau von diesen erneuerbaren Energiequellen bewirkt eine Dezentralisierung der Energieversorgung und vor allem auch größere Schwankungen im Stromnetz. Ein Grund dafür ist, dass tagsüber, wenn die *PV*-Anlage viel Energie produziert, weniger Menschen zu Hause sind und so vor allem in privaten Häusern weniger Energie benötigt wird.

An sehr schönen Tagen im Sommer beispielsweise, kann dies zu einem großen Einspeiseüberschuss führen, der dann vom Stromnetz und den anderen Regelenergieproduzenten wieder kompensiert werden muss. Derzeit können die Spitzen noch gut kompensiert werden, in Zukunft wird dies aber immer schwieriger werden. [2] Um dieser Entwicklung entgegenzuwirken und die selbst produzierte Energie besser nutzen zu können sind Energiemanagement Systeme in den letzten Jahren immer wichtiger und so auch in der Forschung immer prominenter geworden. Diese sollen die Energie, die von erneuerbaren Energiequellen im privaten Sektor produziert wird, so effizient wie möglich nutzen, speichern und zeitlich verteilen um die Energiekosten der Gebäude zu minimieren. Gleichzeitig geht mit der Minimierung der Energiekosten meist auch eine Erhöhung des Eigenverbrauchsanteils einher, wodurch weniger Energie in das Netz eingespeist wird und auch weniger Energie aus dem Netz bezogen werden muss. Dies kann wiederum zur Unterstützung der Netzstabilität beitragen.

Um diese Annahmen zu evaluieren, werden in dieser Arbeit mit Hilfe des modellbasierten heuristischen Optimierungsansatzes von Kefer et al. [3] mehrere heuristische Regler erstellt. Diese haben als alleiniges Ziel die Minimierung der Energiekosten eines Haushalts mit *PV*-Anlage und Batteriespeicher, werden jedoch auf die Unterstützung der Netzstabilität hin geprüft und anhand der vorher vorgestellten Theorie evaluiert.

Die verbleibende Arbeit ist wie folgt strukturiert: Kapitel 2 gibt einen Überblick über die unterschiedlichen Technologien von Energiemanagement Systemen, gefolgt von einer detaillierten Beschreibung der angewandten Methode. Kapitel 4 und 5 beschreiben die durchgeführte Evaluierung und deren Ergebnisse, während das letzte Kapitel noch Schlussfolgerungen und mögliche weiterführende Arbeiten enthält.

## 2 Methoden zur Steuerung von Energieflüssen

Bei der Optimierung von Energieflüssen lassen sich derzeit vier Haupttendenzen erkennen: Regel-basierte Steuerungen, Modellprädiktive Regler (*Model Predictive Controls, MPCs*), *Linear Programming (LP)* Ansätze und vor allem auch Meta-heuristische Optimierungsalgorithmen wie sie auch in dieser Arbeit verwendet werden. Alle Ansätze werden nachfolgend kurz erläutert.

## 2.1 Regel-basierte Steuerungen

Die einfachste Art der Optimierung von Energieflüssen ist eine Regel-basierte Steuerung. Sie basiert auf einfachen Entweder-Oder-Entscheidungen die durch Regeln definiert werden und so im Programmablauf eine Baumstruktur bilden. Die Verzweigungen im Baum stellen dabei die jeweilige Abfrage dar und die Blattknoten der Struktur definieren die Aktionen, die der Algorithmus im jeweiligen Zustand ausführen soll. Für einfache Systeme ist eine solche Steuerung schnell und leicht zu erstellen und kann auch gute Optimierungsergebnisse liefern. Bei komplexen Systemen ist hingegen viel Expertenwissen und Entwicklungsaufwand nötig, um alle möglichen Systemzustände abzubilden und akzeptable Optimierungsergebnisse zu erzielen. Zusätzlich kann der Regelbaum auch sehr schnell komplex und unübersichtlich werden, was zu unerwarteten und ungewollten Nebeneffekten führen kann und einen hohen Anpassungsaufwand bei Änderungen im Systemaufbau mit sich bringt. Durch die einfache Struktur sind diese Steuerungen allerdings sehr performant in der Ausführung und können auch größere Systeme in Echtzeit regeln. Beispiele für ein Regel-basiertes Energiemanagement ist die Eigenverbrauchsoptimierung von Fronius [4], die auch als Vergleichsalgorithmus zu dem in dieser Arbeit vorgestellten Optimierungsansatz herangezogen wird, sowie die Arbeiten von De Coninck et al. aus 2014 [5], Salpakari und Lund aus 2016 [6] und Alimohammadisagvand et al. aus 2018 [7].

## 2.2 Modellprädiktive Regler

Eine weitere, bereits seit den 1980ern bekannte und weit verbreitete Technik zur Energieflussoptimierung sind Modellprädiktive Regler [8]-[10]. Ein *MPC* ist ein lineares oder quadratisches Optimierungsprogramm, das zu einem gewissen Zeitpunkt die optimalen Sollwertvorgaben für den nächsten Zeitpunkt berechnet. Dazu werden die aktuellen Systemwerte für die Vorhersagen über das zukünftige Systemverhalten berechnet. Basierend auf diesen Vorhersagen werden mit Hilfe eines Simulationsmodells des zu optimierenden Systems die neuen, optimalen Anweisungen für den nächsten Zeitpunkt vom Optimierungsalgorithmus berechnet. [11] Durch die Verwendung von möglichst genauen Vorhersagen und einem möglichst exakten Abbild des realen Systems in Form eines Modells läuft ein solcher Regler beinahe optimal. Jedoch sind *MPCs* im Vergleich zu einer Regel-basierten Steuerung in der Implementierung aufwändiger und auch in der Ausführung bedeutend rechenintensiver. Dadurch kann er nur in gewissen Zeitabständen, beispielsweise alle 15 Minuten, ausgeführt werden. Zusätzlich darf der Wartungsaufwand eines *MPCs* nicht unterschätzt werden, da selbst kleine Änderungen des zu regelnden Systems in das Modell und eventuell auch in die Vorhersagen übernommen werden müssen, um wieder gute Ergebnisse erzielen zu können.

## 2.3 Linear Programming Optimierungsalgorithmen zur Steuerung von Energieflüssen

Von den bekannten *Linear Programming* Algorithmen wurden bisher vor allem *Mixed Integer Linear Programming (MILP)* Algorithmen verwendet. Es handelt sich hierbei um Algorithmen, die den Wert einer linearen Qualitätsfunktion minimieren oder maximieren, während gleichzeitig lineare Einschränkungen berücksichtigt und erfüllt werden müssen. *MILP* Algorithmen sind eine Weiterentwicklung beziehungsweise Verfeinerung solcher *Linear*

*Programming* Algorithmen. Darin dürfen die definierten Variablen nicht nur, wie normalerweise von *Integer Programming* Algorithmen gefordert, ganzzahlige Werte haben, sondern können auch kontinuierliche Werte wie reelle Zahlen annehmen. [12] Drei Arbeiten, die einen *Mixed Integer Linear Programming* Ansatz zur Optimierung beziehungsweise Steuerung von Energieflüssen verwenden, wurden 2012 von Hubert et al. [13] und Chen et al. [14] sowie 2013 von Angelis et al. [15] vorgestellt.

## **2.4 Meta-heuristische Optimierungsalgorithmen zur Steuerung von Energieflüssen**

Vor allem in den letzten Jahren ist vermehrt eine Tendenz zur Verwendung von Meta-heuristischen Algorithmen, wie sie auch in dieser Arbeit verwendet werden, erkennbar. Diese Ansätze basieren meist auf biologischen Konzepten wie zum Beispiel der genetischen Vererbung oder dem Schwarmverhalten. Bisher liegt der Fokus eher auf Schwarm-basierten Algorithmen zur Energieflussoptimierung, im Speziellen den *Particle Swarm Optimization (PSO)* Algorithmen [16]-[17]. Abgesehen von den *PSO* Algorithmen werden auch, so wie in dieser Arbeit verwendet, genetische Algorithmen [18] zur Optimierung von Energieflüssen verwendet. Diese haben den natürlichen biologischen Auswahlprozess zum Vorbild, der zum Überleben des "fittesten" Individuums führt. Dafür generieren die Algorithmen ausgehend von einer Elterngeneration durch Kreuzung und zufälliger Mutation neue Lösungskandidaten, von denen nach einer Selektion eine fixe Anzahl in die nächste Generation übernommen wird. Im Laufe des Optimierungsprozesses ist es so möglich einen optimalen Lösungskandidaten zu finden. [18] Zwei Beispiele für die Verwendung eines genetischen Algorithmus für die Optimierung beziehungsweise das Management von Energiequellen und Lasten wurden 2009 von Morganti et al. [19] sowie 2017 von Soares et al. [20] präsentiert.

## **2.5 Zusammenfassung und Vergleich**

Vergleicht man die bestehenden Optimierungstechnologien mit dem in dieser Arbeit verfolgten Ansatz fällt auf, dass ähnlich wie bei *MPCs* auch in dieser Arbeit ein physikalisches Modell des zu optimierenden Systems benötigt wird. Allerdings wird dieses System nur für das Lernen der Regler benötigt und nicht mehr für die eigentliche Optimierung wie bei den *MPCs*. Des Weiteren können mit dem hier vorgestellten Ansatz auch sehr komplexe Systeme optimiert werden, was beispielsweise mit Regel-basierten Steuerungen durch den hohen Aufwand, die möglichen Seiteneffekte sowie das benötigte Expertenwissen nur bedingt möglich ist.

Ein weiteres Alleinstellungsmerkmal dieser Arbeit ist die Anwendung von verschiedenen genetischen Algorithmen zur Lösung des symbolischen Regressionsproblems, da genetische Algorithmen im Allgemeinen, aber vor allem auch in Kombination mit symbolischer Regression bisher nur sehr selten bis gar nicht zur Optimierung von Energieflüssen verwendet wurden. Bei dieser Kombination ist ein Lösungskandidat eine mathematische Formel, die einen Regler repräsentiert. Diese Reglerformel kann anschließend sehr einfach in das vorhandene Modell oder in ein reales Testgebäude integriert und getestet werden. Im Vergleich zu *MPCs*, die durch die lange Rechenzeit ein System nur einmal in einem gewissen Zeitraum optimieren können, ist ein Regler der als Formel repräsentiert wird um ein vielfaches performanter in der Ausführung, was eine engmaschigere Optimierung ermöglicht. Zusätzlich wurden die vorgestellten Arbeiten nur im Hinblick auf die Energiekostenoptimierung beziehungsweise auf

die Optimierung der Energieflüsse evaluiert, während diese Arbeit die Netzstabilität in den Vordergrund stellt.

### 3 Methode

Das zu optimierende System, ein Einfamilienhaushalt mit PV-System und Batteriespeicher, wurde von Kirchsteiger et al. in [21] mit MATLAB Simulink modelliert und für diese Arbeit adaptiert (Abbildung 1). Das Modell verfügt über fünf Eingänge (links), die die aktuellen Daten über die Last des Haushaltes, den aktuellen Ladestand der Batterie, die Produktion der PV-Anlage, den Netzbezugspreis sowie den Einspeisetarif für den Regler bereitstellen. Der Regler berechnet damit die optimale Netzeinspeiseleistung als Vorgabe für den Wechselrichter. Dieser entscheidet dann mittels seiner internen Logik, ob die Batterie noch weiter geladen wird oder ob die verfügbare Energie direkt in das Netz eingespeist wird. Die finalen Energiekosten werden im Block „Evaluierung“ basierend auf der Menge an eingespeister und bezogener Energie sowie deren Tarifen berechnet.

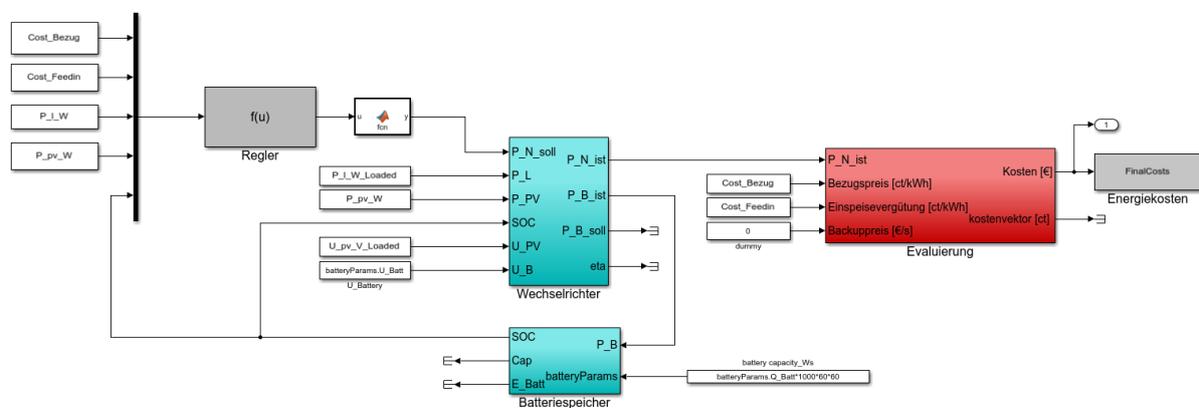


Abbildung 1: Das von Kirchsteiger et al. in [21] modellierte System mit PV-Anlage und Batteriespeicher, das für diese Arbeit adaptiert wurde.

Der zweistufige von Kefer et al. in [3] entwickelte Optimierungsprozess (Abbildung 2) lädt über ein MATLAB Script die für das Training der Regler benötigten Daten in den MATLAB Workspace und stellt sie so der Simulation zur Verfügung. Anschließend wird das eigentliche Training gestartet, bei dem das Optimierungsframework HeuristicLab [22] genetische Algorithmen zur Lösung eines symbolischen Regressionsproblems [23] verwendet. Dafür wird vom Algorithmus initial eine Population von mehreren zufällig erzeugten Lösungskandidaten (Reglern) erstellt. Diese Regler werden als Syntaxbäume repräsentiert, die mathematische Operationen wie Addition oder Subtraktion in den Knoten und Konstanten oder Parameter in den Blattknoten enthalten. Durch Kreuzen und zufälliges Mutieren werden neue Lösungskandidaten basierend auf dieser Elterngeneration generiert. Diese Lösungskandidaten werden über den MATLAB Workspace in das MATLAB Simulink Modell des Systems übernommen und durch Ausführen der Simulation evaluiert. Das Ergebnis der Simulation sind die Energiekosten für den simulierten Zeitraum, welche vom HeuristicLab wiederum aus dem MATLAB Workspace ausgelesen werden. Basierend auf diesem Qualitätswert werden nun mittels eines vorgegebenen Selektionsverfahrens die Lösungskandidaten beziehungsweise Regler ausgewählt, die die neue Elterngeneration bilden. Über mehrere Generationen hinweg werden so die Lösungskandidaten weiterentwickelt, um eine optimale Lösung anzunähern. [3]

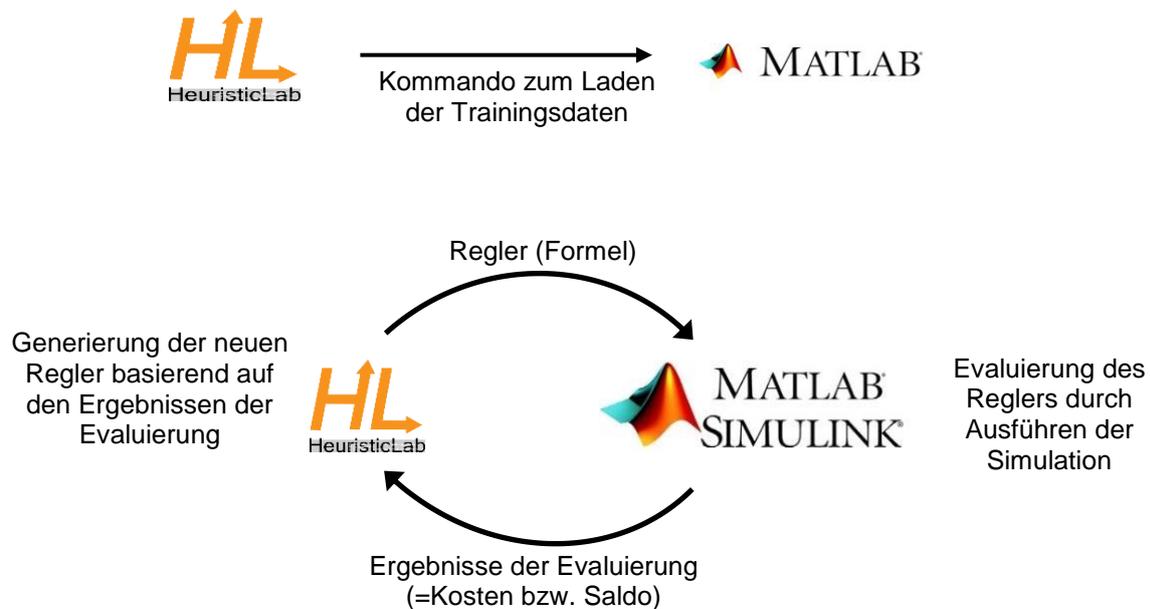


Abbildung 2: Der zweistufige, von Kefer et al. [3] entwickelte Prozess für ein System, das in MATLAB Simulink modelliert wurde und mit dem Optimierungsframework HeuristicLab [22] optimiert wird.

## 4 Evaluierung

Zur Evaluierung der These wurden insgesamt zehn heuristische Regler mit zwei verschiedenen genetischen Algorithmen und 30 Tagen Trainingsdaten trainiert. Die verwendeten Daten wurden von einem Einfamilienhaushalt in Oberösterreich beginnend mit dem 10. Februar 2017 aufgezeichnet und beinhalten die Last des Haushalts in einer 5 Sekunden Auflösung, die Energieproduktion der PV-Anlage in einer 5 Minuten Auflösung sowie den stündlich variablen Netzbezugspreis und den monatlich angepassten Einspeisetarif von *aWATTar*. Der erste verwendete genetische Algorithmus, der Offspring Selection Genetic Algorithm (OSGA) von Affenzeller und Wagner [24], hat als einziges Ziel die Minimierung der Energiekosten. Der Zweite, der Non-Dominated Sorting Genetic Algorithm (*NSGA-II*) [25], ist ein multikriterieller Algorithmus, der zusätzlich zu den Energiekosten auch noch die Komplexität der Reglerformel minimiert. Bei beiden Algorithmen wurde die Anzahl an Generationen auf 100, die Populationsgröße auf 500 sowie die Mutationsrate auf 15% gesetzt. Als Selektoren zur Auswahl der Lösungskandidaten für die nächste Generation wurden für den OSGA ein Gender Specific Selector [26] und für den *NSGA-II* ein Crowded Tournament Selector [27] mit einer Gruppengröße von 6 verwendet.

Die so trainierten Regler werden direkt anschließend an den Trainingszeitraum über 295 Tage von 12. März bis 31. Dezember 2017 in der Simulation evaluiert. Als Vergleichsalgorithmen dienen das aktuelle Energieflussmanagement der Fronius Wechselrichter, eine Regel-basierte Eigenverbrauchsoptimierung, sowie der lineare *MPC* von Kirchsteiger et al. [21]

## 5 Ergebnisse

Wie in Abbildung 3 dargestellt, speisen die heuristisch trainierten Regler im Vergleich zur Eigenverbrauchsoptimierung von Fronius 19.01% bis 27.10% (*NSGA-II*) bzw. 19.00% bis 27.12% (OSGA) weniger Energie in das Netz ein. Werden die Ergebnisse der heuristischen

Regler mit denen des linearen *MPCs* von Kirchsteiger et al. [21] verglichen, erhöhen sich die Prozentsätze auf 54.24% bis 64.72% für die mit dem *NSGA-II* und auf 54.22% bis 64.75% für die mit dem *OSGA* trainierten Regler und führen somit zu einem deutlich höheren Eigenverbrauchsanteil des Haushalts. Zusätzlich wird von den trainierten Reglern 9.88% bis 16.6% (*NSGA-II*) beziehungsweise 9.14% bis 17.33% (*OSGA*) weniger Energie vom Netz bezogen als vom linearen Optimierer. Dies sind ähnliche Werte wie die der Fronius Eigenverbrauchsoptimierung, die eine Einsparung des Netzbezugs von 14.00% im Vergleich zum linearen *MPC* erreicht.

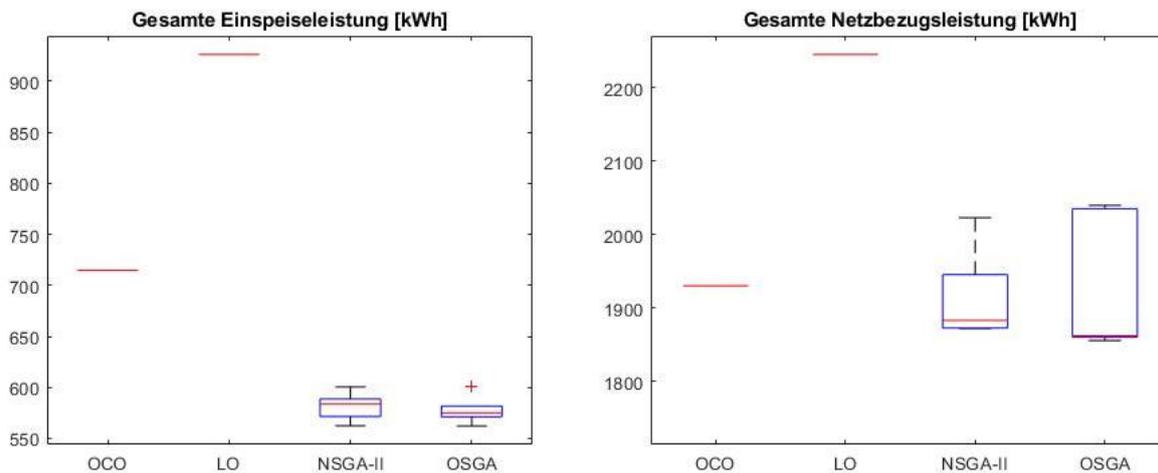


Abbildung 3: Die Einspeiseleistung und die Netzbezugsleistung in kWh pro Regler für den gesamten Evaluierungszeitraum von 295 Tagen im Vergleich zur Regel-basierten Fronius Eigenverbrauchsoptimierung (OCO) und zum linearen *MPC* (LO) von Kirchsteiger et al. [21].

Bis auf eine Ausnahme durch einen Regler der mit dem *NSGA-II* Algorithmus trainiert wurde und eine maximale Einspeiseleistung von 4631.86 W erreicht, werden mit Hilfe der heuristischen Regler auch die Einspeisepeizen reduziert (siehe Abbildung 4). Im Vergleich zum linearen *MPC* (4407.58 W) halbieren die heuristischen Regler mit 2878.35 W bzw. 2878.27 W beinahe die maximale Einspeiseleistung und erreichen so ähnliche Werte wie die Fronius Eigenverbrauchsoptimierung (2870.74 W). Dieses Ergebnis kann dadurch erklärt werden, dass aufgrund der Minimierung der Kosten auch der Eigenverbrauchsanteil erhöht wird und somit weniger Energie als Überschuss in das Netz eingespeist wird.

Des Weiteren sind die Bezugsspitzen der heuristischen Regler bis auf zwei Ausnahmen auf einem ähnlich niedrigen Niveau wie vom linearen *MPC* und der Eigenverbrauchsoptimierung, welche beide maximal 7295.02 W vom Netz beziehen (siehe Abbildung 4). Diese beiden Ausnahmen sind Regler, die einmal mit dem *NSGA-II* und einmal mit dem *OSGA* trainiert wurden und Bezugsspitzen von 12 428.11 W erreichen. Dieser hohe Wert ist jedoch dadurch erklärbar, dass die zu diesem Zeitpunkt bestehenden negativen Strompreise von den Reglern ausgenutzt und die Batterie mit Strom aus dem Netz geladen wird um diese später nutzen zu können. Somit wird der überschüssige Strom im Netz, der diese negativen Stromkosten verursacht, aktiv von den Reglern verwendet, was wiederum zur Unterstützung der Netzstabilität beiträgt (siehe Abbildung 5).

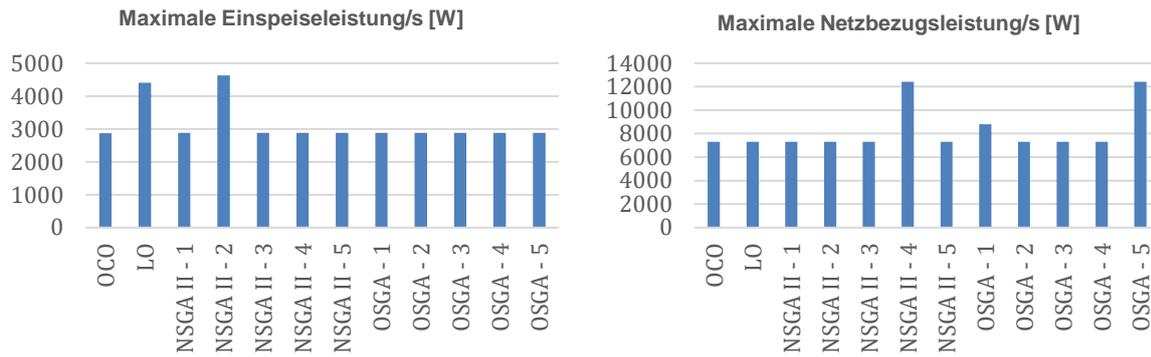


Abbildung 4: Die maximale Einspeise- und Netzbezugsleistung pro Sekunde in Watt für jeden heuristischen Regler im Vergleich zur Regel-basierten Fronius Eigenverbrauchsoptimierung (OCO) und zum linearen MPC (LO) von Kirchsteiger et al. [21].

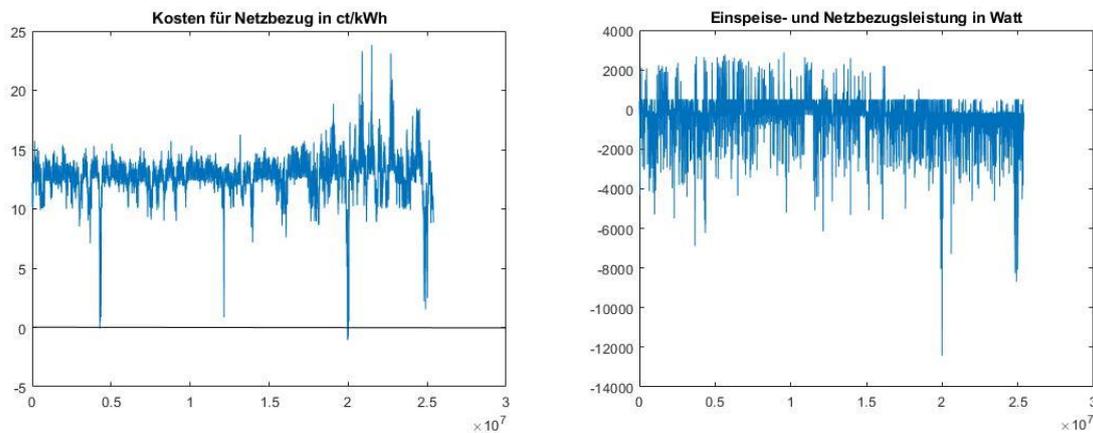


Abbildung 5: Die linke Grafik zeigt die Kosten für den Netzbezug zu jedem Zeitpunkt der Simulation während der Evaluierung. Bei Achsenmarkierung 2 fällt der Netzbezugspreis unter 0 und wird negativ. Zu genau diesem Zeitpunkt weisen zwei der der heuristischen Regler massive Einspeisespitze von 12 428.11 W auf, wodurch die Netzstabilität aktiv unterstützt wird.

## 6 Schlussfolgerungen und zukünftige Arbeiten

In dieser Arbeit wurden heuristische Regler, die mit dem in [3] von Kefer et al. vorgestellten modellbasierten Optimierungsansatz trainiert wurden, auf ihre Unterstützung der Netzstabilität evaluiert. Dafür wurden je fünf Regler mit zwei verschiedenen genetischen Algorithmen zur Lösung des symbolischen Regressionsproblems trainiert, die als Ziel die Minimierung der Energiekosten des Gebäudes haben. Als „Seiteneffekt“ dieser Kostenminimierung wurde erwartet, dass der Eigenverbrauchsanteil der selbst erzeugten Energie erhöht wird und so auch die Netzeinspeise- sowie Netzbezugsspitzen verringert werden. Diese These konnte in der Evaluierung erfolgreich belegt werden. Zusätzlich konnte gezeigt werden, dass einzelne Regler auch aktiv die Netzstabilität unterstützen, indem sie zu Zeiten von sehr geringen oder sogar negativen Strompreisen die durch einen Überschuss im Netz hervorgerufen werden, Bezugsspitzen aufweisen um den Batteriespeicher zusätzlich noch weiter vollzuladen und so den Überschuss im Netz bekämpfen.

Als erste Erweiterung der bestehenden Arbeit ist der Einbau von Prognosen für die Einspeisetarife, die Netzbezugskosten, die Höhe der Produktion der PV-Anlage sowie für die

Haushaltslast geplant. Damit können erneut heuristische Regler in verschiedenen Konfigurationen trainiert werden, die anschließend mit den in dieser Arbeit verwendeten Reglern verglichen werden können. Des Weiteren soll das Gebäudemodell auch noch um thermischen Komponenten, beispielsweise eine Warmwasseraufbereitung durch den Fronius Ohmpilot, erweitert werden. Diese Erweiterung bedingt gleichzeitig auch eine Ausweitung der Optimierung auf mehrere Parameter, was die Komplexität der Optimierung merklich erhöht.

## 7 Referenzen

- [1] BMWi (2019). Gesamtausgabe der Energiedaten: Datensammlung des BMWi. [https://www.bmwi.de/Redaktion/DE/Downloads/Energiedaten/energiedaten-gesamt-pdf-grafiken.pdf?\\_\\_blob=publicationFile&v=40](https://www.bmwi.de/Redaktion/DE/Downloads/Energiedaten/energiedaten-gesamt-pdf-grafiken.pdf?__blob=publicationFile&v=40), S. 35. Zuletzt besucht am 25.1.2020
- [2] EP Photovoltaik des AK Verteilernetze (2014). Abschlussbericht des EP Photovoltaik. [https://oesterreichsenergie.at/files/Downloads%20Netze/Abschlussbericht\\_EP\\_PV.pdf](https://oesterreichsenergie.at/files/Downloads%20Netze/Abschlussbericht_EP_PV.pdf). S. 12 ff. Zuletzt besucht am 25.1.2020
- [3] Kefer, K., Hanghofer, R., Kefer, P., Stöger, M., Affenzeller, M., Winkler, S., Wagner, S., Hofer, B. (2019). A Model-Based Learning Approach for Controlling the Energy Flows of a Residential Household Using Genetic Programming to Perform Symbolic Regression. *Computer Aided Systems Theory – EUROCAST 2019*, S. 110-111
- [4] <https://www.fronius.com/de/solarenergie/kompetenzen/energieflussmanagement>. Zuletzt besucht am 27.1.2020
- [5] De Coninck, R., Baetens, R., Saelens, D., Woyte, A., Helsen, L. (2014). Rule-based demand-side management of domestic hot water production with heat pumps in zero energy neighbourhoods. *Journal of Building Performance Simulation*, 7(4), S. 271-288.
- [6] Salpakari, J., Lund, P. (2016). Optimal and rule-based control strategies for energy flexibility in buildings with PV. *Applied Energy*, 161, S. 425-436.
- [7] Alimohammadisagvand, B., Jokisalo, J., Sirén, K. (2018). Comparison of four rule-based demand response control algorithms in an electrically and heat pump-heated residential building. *Applied Energy*, 209, S. 167-179.
- [8] Chen, C., Wang, J., Heo, Y., Kishore, S. (2013). MPC-Based Appliance Scheduling for Residential Building Energy Management Controller. *IEEE Transactions on Smart Grid* 4.3, S. 1401–1410
- [9] Figueiredo, J., Sá da Costa, J. (2012). A SCADA system for energy management in intelligent buildings. *Energy and Buildings* 49.Supplement C, S. 85–98.
- [10] Kennel, F., Görges, D., Liu, S. (2013). Energy Management for Smart Grids With Electric Vehicles Based on Hierarchical MPC. *IEEE Transactions on Industrial Informatics* 9.3, S. 1528–1537
- [11] Kothare, M. V., Balakrishnan, V., Morari, M. (1996). Robust constrained model predictive control using linear matrix inequalities“. *Automatica* 32.10, S. 1361–1379
- [12] Matousek, J., Gärtner, B. (2007). Understanding and using linear programming. Springer Science & Business Media
- [13] Hubert, T., Grijalva, S. (2012). Modeling for Residential Electricity Optimization in Dynamic Pricing Environments. *IEEE Transactions on Smart Grid* 3.4, S. 2224–2231
- [14] Chen, Z., Wu, L., Fu, Y. (2012). Real-Time Price-Based Demand Response Management for Residential Appliances via Stochastic Optimization and Robust Optimization. *IEEE Transactions on Smart Grid* 3.4, S. 1822–1831
- [15] De Angelis, F., Boaro, M., Fuselli, D., Squartini, S., Piazza, F., Wei, Q. (2013). Optimal Home Energy Management Under Dynamic Electrical and Thermal Constraints. *IEEE Transactions on Industrial Informatics* 9.3, S. 1518–1527
- [16] Pedrasa, M. A. A., Spooner, T. D., MacGill, I. F. (2010) Coordinated Scheduling of Residential Distributed Energy Resources to Optimize Smart Home Energy Services. *IEEE Transactions on Smart Grid* 1.2, S. 134–143
- [17] Wang, Z., Yang, R., Wang, L. (2010). Multi-agent control system with intelligent optimization for smart and energy-efficient buildings. *IECON 2010 - 36<sup>th</sup> Annual Conference on IEEE Industrial Electronics Society*, S. 1144–1149
- [18] Srinivas, M., Patnaik, L. M. (1994) Genetic algorithms: a survey. *Computer* 27.6, S. 17–26

- [19] Morganti, G., Perdon, A. M., Conte, G., Scaradozzi, D., Brintrup, A. (2009) Optimising Home Automation Systems: A comparative study on Tabu Search and Evolutionary Algorithms. 17th Mediterranean Conference on Control and Automation, S. 1044–1049
- [20] Soares, A., Gomes, A., Antunes, C. H., Oliveira, C. (2017) A Customized Evolutionary Algorithm for Multiobjective Management of Residential Energy Resources. IEEE Transactions on Industrial Informatics 13.2, S. 492–501
- [21] Kirchsteiger, H., Rechberger, P., Steinmaurer, G. (2016) Cost-optimal Control of Photovoltaic Systems with Battery Storage under Variable Electricity Tariffs. Elektrotech. Inftech 133/8, S. 371-380
- [22] Wagner, S., Beham, A., Kronberger, G., Kommenda, M., Pitzer, E., Kofler, M., Affenzeller, M. (2013) HeuristicLab 3.3: A unified approach to metaheuristic optimization. Actas del séptimo congreso español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados, S. 8
- [23] Riolo, Rick. (2013) Genetic programming theory and practice X. Springer
- [24] Affenzeller, M., Wagner, S., Winkler, S., Beham, A. (2009) Genetic Algorithms and Genetic Programming: Modern Concepts and Practical Applications. New York: Chapman and Hall/CRC
- [25] Deb, K., Pratap, A., Agarwal, S., Meyarivan, T. A. M. T. (2002) A fast and elitist multiobjective genetic algorithm: NSGA-II, IEEE transactions on evolutionary computation, 6(2), S. 182-197
- [26] Wagner, S., Affenzeller, M. (2005). SexualGA: Gender-specific selection for genetic algorithms. Proceedings of the 9th World Multi-Conference on Systemics, Cybernetics and Informatics (WMSCI). Vol. 4, pp. 76-81.
- [27] Deb, K. (2001). Multi-objective optimization using evolutionary algorithms (Vol. 16). John Wiley & Sons. S. 247 ff.