

# **En4U – Entwicklungspfade eines dezentralen Energiesystems im Zusammenspiel der Entscheidungen privater und kommerzieller Energieakteure unter Unsicherheit**

## **Schlussbericht**

**BMWK – FKZ 03EI1029A & 03EI1029B**

Im Rahmen des 7. Energieforschungsprogramm  
„Innovationen für die Energiewende“,  
3.14 Technologieorientierte Systemanalyse

### **Verbundpartner:**

Deutsches Zentrum für Luft- und Raumfahrt (DLR)  
Institut für Vernetzte Energiesysteme  
Abteilung Energiesystemanalyse, Stuttgart

Karlsruher Institut für Technologie (KIT)  
Institut für Industriebetriebslehre und Industrielle Produktion (IIP), Karlsruhe

### **AutorInnen:**

DLR: Ulrich Frey, A. Achraf El Ghazi, Evelyn Sperber, Fabia Miorelli, Kristina Nienhaus

KIT: Stephanie Stumpf, Daniel Slood, Wolf Fichtner, Anil Kaya, Steffen Rebennack

Stuttgart und Karlsruhe, 31. Januar 2025

*Gefördert vom Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren. Die Verantwortlichkeiten sind in Kapitelüberschriften den Verbundpartnern jeweils zugeordnet und mit der Abkürzung der Institutsbezeichnungen gekennzeichnet. Insoweit nicht anders gekennzeichnet, gelten für Unterkapitel die gleichen Verantwortlichkeiten wie in den Hauptkapiteln.*

Gefördert durch:



aufgrund eines Beschlusses  
des Deutschen Bundestages

## **Kontakt:**

Ulrich Frey  
[Ulrich.Frey@dlr.de](mailto:Ulrich.Frey@dlr.de)  
Deutsches Zentrum für Luft- und Raumfahrt (DLR)  
Institut für Vernetzte Energiesysteme  
Abteilung Energiesystemanalyse  
Curiestr. 4, 70563 Stuttgart

Stephanie Stumpf  
[stephanie.stumpf@kit.edu](mailto:stephanie.stumpf@kit.edu)  
Karlsruher Institut für Technologie (KIT)  
Institut für Industriebetriebslehre und Industrielle Produktion (IIP)  
Hertzstr. 16, 76131 Karlsruhe

# Inhaltsverzeichnis

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>Kurzfassung und Abstract</b>   | <b>6</b>  |
| 1.1      | Executive Summary   | 6         |
| 1.2      | Kurzzusammenfassung   | 8         |
| <b>2</b> | <b>Einleitung und Ziele</b>   | <b>10</b> |
| 2.1      | Ziele   | 10        |
| 2.2      | Forschungsfragen  | 11        |
| 2.3      | Aufbau des Projekts   | 11        |
| 2.4      | Aufbau dieses Berichts  | 12        |
| <b>3</b> | <b>Methodenentwicklung DLR: AMIRIS, Mikromodelle PVS, E-Pkw und Wärmepumpen, sowie ML-Modelle (DLR)</b> | <b>12</b> |
| 3.1      | Weiterentwicklung des Simulationsmodells AMIRIS   | 12        |
| 3.1.1    | Einführung in das Modell  | 12        |
| 3.1.2    | Modellerweiterung   | 14        |
| 3.1.3    | Zusammenfassung   | 16        |
| 3.2      | Weiterentwicklung des Mikromodells Photovoltaik   | 17        |
| 3.2.1    | Beschreibung des PVS-Optimierungsproblems   | 18        |
| 3.2.2    | Modellerweiterung   | 18        |
| 3.2.3    | Zusammenfassung   | 19        |
| 3.3      | Weiterentwicklung des Mikromodells Wärmepumpen  | 19        |
| 3.3.1    | Einführung in das Modell  | 19        |
| 3.3.2    | Modellerweiterung   | 19        |
| 3.3.3    | Zusammenfassung   | 21        |
| 3.4      | Weiterentwicklung des Mikromodells Elektromobilität   | 21        |
| 3.4.1    | Einführung in das Modell  | 21        |
| 3.4.2    | Modellerweiterung   | 22        |
| 3.4.3    | Zusammenfassung   | 29        |
| 3.5      | Weiterentwicklung des Maschinellen Lernens bei der Lastaggregation                                      | 29        |
| 3.5.1    | Einführung  | 29        |
| 3.5.2    | Modellerweiterung   | 30        |
| 3.5.3    | Zusammenfassung und neue Erkenntnisse   | 33        |
| <b>4</b> | <b>Methodenentwicklung IIP: Diffusionsmodell (IIP)</b>  | <b>33</b> |
| 4.1      | Einführung in das Modell  | 33        |
| 4.2      | Modellerweiterung   | 34        |

|           |  |           |
|-----------|--|-----------|
| 4.3       | Zusammenfassung und neue Erkenntnisse.....   | 36        |
| <b>5</b>  | <b>Methodenentwicklung IOR: stochastisches Optimierungsmodell (IOR) .....</b>          | <b>36</b> |
| 5.1       | Einführung in das Modell .....   | 36        |
| 5.2       | Modellerweiterung.....   | 37        |
| 5.2.1     | Lösungsalgorithmus.....  | 38        |
| 5.2.2     | Integration von AMIRIS in das PGEP-Problem.....  | 41        |
| 5.2.3     | Kopplungsstrategien: Integration von AMIRIS in das Optimierungsmodell.....             | 42        |
| 5.3       | Zusammenfassung und neue Erkenntnisse.....   | 45        |
| <b>6</b>  | <b>Methodenentwicklung DLR und IOR: Kopplung PGEP und AMIRIS (DLR &amp; IOR) .....</b> | <b>45</b> |
| 6.1       | Motivation .....   | 45        |
| 6.2       | Beschreibung der Kopplungssoftware RCE .....   | 46        |
| 6.3       | Vorgehen der Modellkopplung .....  | 47        |
| 6.4       | Zusammenfassung und neue Erkenntnisse.....   | 48        |
| <b>7</b>  | <b>Datengrundlage .....</b>  | <b>49</b> |
| 7.1       | Vorbereitende Analyse politischer Unsicherheiten (IIP) .....                           | 49        |
| 7.2       | Szenarien .....  | 49        |
| 7.2.1     | Grundlagen der Szenarioentwicklung .....   | 49        |
| 7.2.2     | Verwendete Daten .....   | 50        |
| 7.2.3     | Einbindung der Szenarien in AMIRIS .....   | 51        |
| 7.2.4     | Einbindung der Szenarien in SOM .....  | 51        |
| 7.3       | AMIRIS (DLR).....  | 52        |
| 7.4       | Mikromodelle .....   | 52        |
| 7.5       | SOM (IOR) .....  | 52        |
| 7.6       | Diffusionsmodell (IIP) .....   | 53        |
| <b>8</b>  | <b>Ergebnisse .....</b>  | <b>53</b> |
| 8.1       | Ergebnisse AMIRIS mit integrierten ML-Modellen (DLR) .....                             | 53        |
| 8.2       | Ergebnisse Mikromodell Photovoltaik + Speicher (PVS) (DLR).....                        | 54        |
| 8.3       | Ergebnisse Mikromodell Wärmepumpen (DLR).....  | 57        |
| 8.4       | Ergebnisse Mikromodell E-Mobilität (DLR) .....   | 60        |
| 8.5       | Ergebnisse Maschinelles Lernen (DLR).....  | 62        |
| 8.6       | Ergebnisse Diffusionsmodell (IIP) .....  | 65        |
| 8.7       | Ergebnisse Modellkopplung PGEP-AMIRIS (DLR & IOR).....                                 | 67        |
| <b>9</b>  | <b>Zusammenfassung .....</b>   | <b>72</b> |
| <b>10</b> | <b>Schlussfolgerungen .....</b>  | <b>73</b> |

|           |   |           |
|-----------|---|-----------|
| <b>11</b> | <b>Verwendung der Zuwendung</b> .....                       | <b>74</b> |
| 11.1      | Bezug zu förderpolitischen Zielen .....                     | 74        |
| 11.2      | Erfolgte und geplante Veröffentlichung der Ergebnisse ..... | 74        |
| <b>12</b> | <b>Abbildungsverzeichnis</b> .....                          | <b>78</b> |
| <b>13</b> | <b>Tabellenverzeichnis</b> .....                            | <b>79</b> |
| <b>14</b> | <b>Abkürzungsverzeichnis</b> .....                          | <b>80</b> |
| <b>15</b> | <b>Literaturverzeichnis</b> .....                           | <b>81</b> |

# 1 Kurzfassung und Abstract

## 1.1 Executive Summary

The EN4U project aims to understand and quantify uncertainties, e.g. regarding the future composition of the power plant park, the development of demand or the behaviour of stakeholders in the German energy system as a whole. This is achieved through the complex interaction and coupling of many models. First, a stochastic optimisation model (SOM) determines the power plant fleet for a scenario year. An agent-based simulation (ABMS) uses this to calculate their economic utilisation, the electricity price and other variables and feeds this changed utilisation back to the SOM.

Three technologies central to the energy transition – photovoltaics with storage (PVS), electric cars and heat pumps – are optimised from a business perspective as so-called micro-models. This means that many individual decisions, such as charging or discharging (electric cars) or feeding in or out (PV systems and heat pumps), are optimised on the basis of price signals. The price signals simulate future price-based flexibility, driven by the economic profit maximisation of the players.

In a subsequent step, the simulation (AMIRIS, an agent-based simulation of the electricity markets and their players) in turn integrates these three technologies – photovoltaics with storage, electric cars and heat pumps – i.e. the already price-based optimised micro-models as agents. As this would be too time-consuming within the simulation, the price-based decisions to feed energy into or out of the grid at household level are aggregated per technology and abstracted using machine learning. This aggregation of the micro-models therefore provides the total load per technology for the entire electricity system, dynamically per simulation step (1 hour). In this way, the German households are integrated into a national model with a small error via ML models.

If these micro-models are combined with a diffusion model, the economically optimised investment decisions of households up to 2045 can be represented. These future paths of the German energy system are robust, as both the power plant park is stochastically optimised, the aggregated load is based bottom-up on optimised household decisions, and a diffusion model forecasts the distribution of the three most important technologies in detail.

Five important results emerge:

A first project objective was to increase the understanding of the influence of an uncertain environment on household energy decisions using the example of three new technologies (PVS, electric vehicles and heat pumps) in terms of market penetration. This was achieved by developing specific models (micro-models) for each of these technologies.

This means that these three models – electric vehicles, heat pumps, and PV systems with storage – are now able to respond to electricity price signals at the household level. For electric vehicles, the results show that the mobility patterns and the resulting charging load of electric vehicles strongly depend on the household and building type. However, this behaviour can be influenced by electricity costs. The model is able to depict precisely these relationships. In particular, two clusters of household types can be differentiated in their mobility patterns and their reaction to price signals can be modelled.

Simulating price-based heat pump operation in AMIRIS shows that flexible operation under real-time pricing (RTP) can slightly reduce the maximum residual load (by 3 to 5 GW by 2040, which corresponds to around 3%). From the user's perspective, cost-minimising heat pump operation with RTP can result

in annual gross electricity cost savings of 6% to 27% compared to inflexible operation, depending on the building type. These savings are significantly amplified by on-site photovoltaic (PV) self-consumption, reaching up to 74% for users with high comfort tolerance living in well-insulated buildings with high thermal inertia.

Second, the interactions of these household actors in the electricity market were to be analysed in order to draw conclusions for future developments in the electricity market. This was realised by abstracting the individual decisions of the three micro-models mentioned above using machine learning. This means that the sum of the individual decisions, i.e. the total load, can be modelled using ML.

The machine learning algorithms developed in the project (in particular Long Short-term Memory (LSTM) and Temporal Fusion Transformers) are able to predict Germany's aggregated electricity consumption of photovoltaics and storage, heat pumps and electric cars for one year and based on only 3-5 inputs such as solar radiation or price signals quite accurately. Overall, the mean absolute error (MAE) is ~680 MWh. With a range between -22 949 MWh and +11 126 MWh, this is a satisfactory result. Overall, the feed-in and power consumption of PVS households can therefore be mapped well by ML.

A third objective was to gain important insights into the levers of the future energy system. This was achieved by coupling a stochastic optimisation model (SOM) and an ABMS (AMIRIS). This coupling was successful, albeit very time-consuming. However, both models converged after a few iterations. This allowed the advantages of a SOM and an ABMS to be combined, i.e. to iteratively compare uncertainties in future power plant utilisation with actor decisions.

This leads to robust scenario paths, as massive uncertainties in power plant expansion are calculated and considered, while the decisions of the players on the electricity market are taken into account by the micro-models and their numerical development by the diffusion model. This means that complex uncertainties relating to the future power plant fleet, the decisions of the players and their diffusion can be modelled. Most scenarios show similar patterns: oil technology is phased out, while the capacities of wind (81-87%) and natural gas technologies (15-18%) are increased, depending on the coupling and scenario.

Fourthly, the diffusion model developed for PVS and electric vehicles, based on two representative surveys, is able to predict the diffusion of these two technologies in Germany by 2045 for individual household types.

One result of this diffusion model in particular is that the integration of electric cars into existing PV systems increases self-consumption, reduces electricity costs and improves economic efficiency in the long term. The influence of end customer electricity price trends and technology costs on investment decisions was also analysed. Not surprisingly, an increase in electricity prices leads to more investment in larger battery storage systems, while falling technology costs also favour larger battery storage systems and lead to higher capital values. Combining the optimal battery sizes with the forecast diffusion figures results in a cumulative total capacity of 105.3 GW of new PV installations in the buildings analysed in the household sector from 2024 up to and including 2045, as well as 70.6 GWh of cumulative storage capacity.

A fifth project objective was to map the decision-making logic of key players more accurately in order to better understand the effects of regulatory framework conditions. This was achieved as it is now

possible to have any agents communicate with AMIRIS as external ML models at runtime via a new interface. This is already integrated for the three flexibilities – heat pumps, electric cars and PVS.

The objective of modelling complex market interactions, considering the effects of uncertainties, has thus been achieved. All further details on these results can be found in Section 8, Results.

## 1.2 Kurzzusammenfassung

Das Projekt EN4U hat den Anspruch, Unsicherheiten, z.B. die zukünftige Kraftwerksparkzusammensetzung, die Nachfrageentwicklung oder das Akteursverhalten im Strommarkt, im Gesamtzusammenhang des Energiesystems Deutschland zu verstehen und zu quantifizieren. Dies geschieht über das komplexe Zusammenspiel und die Kopplung vieler Modelle. Zunächst bestimmt ein stochastisches Optimierungsmodell (SOM) den Kraftwerkspark für ein Szenariojahr. Damit kalkuliert eine agenten-basierte Simulation (ABMS) deren betriebswirtschaftlichen Einsatz, den Strompreis und andere Größen und gibt diesen veränderten Einsatz zurück an das SOM.

Drei für die Energiewende zentrale Technologien – Photovoltaik mit Speicher (PVS), E-Pkw, und Wärmepumpen – werden betriebswirtschaftlich optimiert, als sogenannte Mikromodelle. Das bedeutet, dass viele Einzelentscheidungen, wie das Laden oder Entladen (E-Pkw) bzw. das Ein- oder Ausspeisen (PVS und Wärmepumpen) auf Grund von Preissignalen optimiert werden. Die Preissignale simulieren dabei eine zukünftige preisbasierte Flexibilität, getrieben durch ökonomische Profitmaximierung der Akteure.

Die Simulation (AMIRIS, eine agentenbasierte Simulation der Strommärkte und ihrer Akteure) wiederum integriert in einem folgenden Schritt diese drei Technologien – Photovoltaik mit Speicher, E-Pkw, und Wärmepumpen – also die bereits preisbasiert optimierten Mikromodelle als Agenten. Da dies innerhalb der Simulation zu zeitintensiv ist, werden die preisbasierten Entscheidungen des Ein- oder Ausspeisens auf Haushaltsebene pro Technologie aggregiert und über maschinelles Lernen abstrahiert. Durch diese Aggregation der Mikromodelle erhält man also die Gesamtlast pro Technologie für das Gesamtstromsystem, dynamisch pro Simulationsschritt (1 Stunde). So sind die deutschen Haushalte mit einem kleinen Fehler über ML-Modelle in ein nationales Modell eingebunden.

Kombiniert man diese Mikromodelle in AMIRIS mit einem Diffusionsmodell, lassen sich so die betriebswirtschaftlich optimierten Investitionsentscheidungen von Haushalten bis 2045 darstellen. Diese zukünftigen Pfade des deutschen Energiesystems sind robust, da sowohl der Kraftwerkspark stochastisch optimiert ist, die aggregierte Last *bottom-up* auf optimierten Haushaltsentscheidungen beruht, und ein Diffusionsmodell die Verteilung der drei wichtigsten Technologien detailliert prognostiziert.

Es ergeben sich fünf wichtige Ergebnisse:

Ein erstes Projektziel war es, das Verständnis des Einflusses einer unsicheren Umwelt auf Haushaltsentscheidungen im Energiebereich am Beispiel dreier neuer Technologien (PVS, E-Pkw und Wärmepumpen) in Bezug auf Marktdurchdringung zu erhöhen. Dies wurde durch die Entwicklung spezieller Modelle (Mikromodelle) für jede dieser Technologien erreicht.

Das bedeutet, dass diese drei Modelle – E-Pkw, Wärmepumpen, und PV-Anlagen mit Speichern – auf der Haushaltsebene jetzt in der Lage sind, auf Strompreissignale zu reagieren. Für E-Pkw zeigen die Ergebnisse, dass die Mobilitätsmuster und die daraus resultierende Ladelast von E-Pkw stark vom Haushalts- und Gebäudetyp abhängen. Dieses Verhalten kann jedoch durch die Stromkosten beeinflusst werden. Das Modell ist in der Lage, genau diese Zusammenhänge abzubilden. Insbesondere zwei Cluster von Haushaltstypen können in ihren Mobilitätsmustern unterschieden und in ihrer Reaktion auf Preissignale genau abgebildet werden.



Simuliert man den preisbasierten Wärmepumpenbetrieb in AMIRIS, so zeigt sich, dass der flexible Betrieb unter Real-Time-Pricing (RTP) die maximale Residuallast leicht reduzieren kann (um 3 bis 5 GW bis 2040, was etwa 3% entspricht). Aus Nutzersicht kann der kostenminimierende Wärmepumpenbetrieb mit RTP im Vergleich zum unflexiblen Betrieb jährliche Bruttostromkosteneinsparungen von 6 % bis 27 % bringen, je nach Gebäudetyp. Diese Einsparungen werden durch den Eigenverbrauch von Photovoltaik (PV) vor Ort noch erheblich verstärkt und erreichen bis zu 74% für Nutzer mit hoher Komforttoleranz, die in gut isolierten Gebäuden mit hoher thermischer Trägheit wohnen.

Zweitens sollten die Wechselwirkungen dieser Haushaltsakteure am Strommarkt untersucht werden, um daraus Schlüsse für zukünftige Entwicklungen des Strommarkts zu ziehen. Dies wurde umgesetzt, indem die Einzelentscheidungen der drei oben genannten Mikromodelle über maschinelles Lernen abstrahiert wurden. Das bedeutet, dass die Summe der Einzelentscheidungen, d.h. die Gesamtlast, durch ML abgebildet werden kann.

Die im Projekt entwickelten Algorithmen des maschinellen Lernens (insbesondere Long Short-term Memory (LSTM) und Temporal Fusion Transformers) sind in der Lage, den aggregierten Stromverbrauch Deutschlands von Photovoltaik und Speichern, Wärmepumpen und E-Pkw für ein Jahr und auf der Grundlage von nur 3-5 Eingaben wie Sonneneinstrahlung oder Preissignalen ziemlich genau vorherzusagen. Insgesamt liegt der mittlere absolute Fehler (MAE) bei  $\sim 680$  MWh. Bei einer Spanne zwischen  $-22\,949$  MWh und  $+11\,126$  MWh ist das ein zufriedenstellendes Ergebnis. Die Einspeisung und Stromentnahme von PVS-Haushalten kann also insgesamt gut durch ML abgebildet werden.

Ein drittes Ziel war es, wichtige Einsichten über Stellschrauben des zukünftigen Energiesystems zu gewinnen. Dies erfolgte durch die Kopplung eines stochastischen Optimierungsmodells (SOM) und eines ABMS (AMIRIS). Diese Kopplung war erfolgreich, wenn auch sehr zeitintensiv. Beide Modelle konvergieren jedoch nach einigen Iterationen. So konnten die Vorteile eines SOM und eines ABMS kombiniert werden, d.h. Unsicherheiten im künftigen Kraftwerkeinsatz mit Akteursentscheidungen iteriert abzugleichen.

Dies führt zu robusten Szenariopfaden, da massive Unsicherheiten im Kraftwerkszubau berechnet und berücksichtigt werden, während die Entscheidungen der Akteure am Strommarkt durch die Mikromodelle und deren zahlenmäßige Entwicklung durch das Diffusionsmodell damit hineinspielen. Damit ist die Abbildung komplexer Unsicherheiten bezüglich des künftigen Kraftwerkparcs, der Akteursentscheidungen und deren Diffusion erreicht. In den meisten Szenarien zeigen sich ähnliche Muster: Öltechnologie wird ausgemustert, während die Kapazitäten von Wind- (81-87%) und Erdgastechnologien (15-18%) erhöht werden, je nach Kopplung und Szenario.

Viertens ist das entwickelte Diffusionsmodell für PVS und E-Pkw, basierend auf zwei repräsentativen Umfragen, in der Lage, die Verbreitung von diesen zwei Technologien in Deutschland bis zum Jahr 2045 für individuelle Haushaltstypen vorherzusagen.

Ein Ergebnis dieses Diffusionsmodells ist insbesondere, dass die Integration von E-Pkw in bestehende PV-Systeme den Eigenverbrauch erhöht, Stromkosten senkt und die Wirtschaftlichkeit langfristig verbessert. Auch der Einfluss von Endkundenstrompreisentwicklungen und Technologiekosten auf Investitionsentscheidungen wurde untersucht. Nicht überraschend führt ein Strompreisanstieg zu mehr Investitionen in größere Batteriespeicher, während sinkende Technologiekosten ebenfalls größere Batteriespeicher begünstigen und zu höheren Kapitalwerten führen. Verknüpft man die optimalen Batteriegrößen mit den prognostizierten Diffusionszahlen ergibt sich ab dem Jahr 2024 bis einschließlich 2045 eine kumulierte Gesamtkapazität der PV-Neuinstallationen bei den betrachteten Gebäuden im Haushaltssektor von 105,3 GW sowie 70,6 GWh kumulierte Speicherkapazität.

Ein fünftes Projektziel war es, die Entscheidungslogiken wichtiger Akteure genauer abzubilden, um die Auswirkungen regulatorischer Rahmenbedingungen besser zu verstehen. Das ist gelungen, da es nun

möglich ist, beliebige Agenten als externe ML-Modelle über eine neue Schnittstelle mit AMIRIS zur Laufzeit kommunizieren zu lassen. Für die drei Flexibilitäten – Wärmepumpen, E-Pkw und PVS – ist das bereits integriert.

Damit ist die Zielstellung, komplexe Marktwechselwirkungen unter Berücksichtigung der Auswirkungen von Unsicherheiten abzubilden, erreicht worden. Alle weiteren Details zu diesen Ergebnissen finden sich im Abschnitt 8, Ergebnisse.

## 2 Einleitung und Ziele

### 2.1 Ziele

Die präzise Modellierung von Unsicherheiten in der Energiesystemanalyse ist für zukünftige Energiesysteme von zentraler Bedeutung. Das Ziel des Projekts war es, die Betriebs- und Investitionsentscheidungen von Haushalten und professionellen Akteuren im Energiesektor zu analysieren, insbesondere in Bezug auf drei wichtige Technologien mit unterschiedlichem Marktdurchdringungsgrad, PVS, E-Pkw und Wärmepumpen. Dabei wird untersucht, wie Unsicherheiten, wie z.B. Marktveränderungen und politische Rahmenbedingungen, die Entscheidungen beeinflussen. Dazu gehört auch die Analyse des zukünftigen Kraftwerkparks unter Einfluss von Unsicherheiten.

Im Projekt wurden in einem ersten Schritt die Unsicherheiten, denen Energieakteure ausgesetzt sind, analysiert und quantifiziert, d.h. wie unsichere Rahmenbedingungen die Haushaltsentscheidungen im Energiebereich, besonders bei PVS, E-Pkw und Wärmepumpen, beeinflussen. Dies wurde durch die Entwicklung spezieller Mikromodelle erreicht. Dabei wurden nicht nur – wie so häufig in der Energiemarktforschung – ökonomische, meteorologische oder politische Unsicherheiten betrachtet, sondern auch gesellschaftliche und qualitative Aspekte, die oft vernachlässigt werden. Unter Berücksichtigung dieser Unsicherheiten und weiterer relevanter Faktoren (wie z. B. Förderinstrumenten) wurde die zukünftige Marktdurchdringung der drei genannten Technologien mittels Diffusionsmodellen analysiert.

Ein weiteres Ziel war die Untersuchung der Wechselwirkungen der Haushaltsakteure am Strommarkt, um zukünftige Marktentwicklungen abzuleiten. Es ist jedoch schwierig, individuelle Entscheidungen auf die Systemebene zu übertragen. Dies wurde umgesetzt, indem die Einzelentscheidungen der Mikromodelle mithilfe von maschinellem Lernen abstrahiert und die Gesamtlast abgebildet wurde. Der Betrieb dieser Technologien in den Haushalten wurde zunächst auf Einzelhaushaltsebene modelliert und dann mittels neuronaler Netze (NN) so abstrahiert, dass die Betriebsentscheidungen sowie die daraus resultierende Nachfrage in umfassende Energiesystemmodelle effizient integriert werden konnten.

Um die Forschungsfrage „Wie interagieren Haushaltsentscheidungen im Energiebereich mit den Entscheidungen von Kraftwerksportfolien am Strommarkt?“ zu beantworten, wurde ein stochastisches Optimierungsmodell (SOM) mit einem agentenbasierten Modell (AMIRIS) gekoppelt. Diese Kopplung erlaubt es, Unsicherheiten im Kraftwerkeinsatz mit den Entscheidungen der Akteure zu verknüpfen.

Schließlich war die Vorhersage der unsicheren Pfade der drei Technologien ein wichtiges Ziel. Die Entwicklung eines Diffusionsmodell für PVS und E-Pkw, basierend auf zwei repräsentativen Umfragen ermöglicht dies bis 2045.

Unter Berücksichtigung dieser Wechselwirkungen wurden schließlich explorative Entwicklungspfade des Energiesystems analysiert und zur Unterstützung von Entscheidungen über Politikinstrumente und regulatorische Rahmenbedingungen aufbereitet.

Durch Entwicklung und Kopplung einer Simulation, einer stochastischen Optimierung, sowie durch ML-abstrahierten Mikromodellen wurden die erheblichen Unsicherheiten bezüglich der zukünftigen

Angebots- und Nachfrageseite für Deutschland abgebildet und analysiert. So konnten die komplexen Marktwechselwirkungen unter Berücksichtigung der Auswirkungen von Unsicherheiten abgebildet werden.

## 2.2 Forschungsfragen

Die Forschungsfragen in En4U lauten wie folgt:

- Wie lassen sich Investitionsentscheidungen von Haushalten unter Unsicherheit darstellen?
- Wie lassen sich robuste Szenariopfade erstellen, die wirtschaftlich tragfähig sind?
- Wie können Betriebsentscheidungen einzelner Haushalte adaptiv und effizient in Strommarktmodelle integriert werden?
- Wie können Unsicherheiten bzgl. der Marktdiffusion von PVS, E-Pkw und Wärmepumpen in agentenbasierten Simulationsmodellen berücksichtigt werden?
- Welche Konsequenzen haben Unsicherheiten für Investitions- und Betriebsentscheidungen von Kraftwerksportfolien mit konventionellen und fluktuierend erneuerbaren Erzeugungstechnologien in Verbindung mit Stromspeichertechnologien?
- Wie interagieren Haushaltsentscheidungen im Energiebereich mit den Entscheidungen von Kraftwerksportfolien am Strommarkt?

## 2.3 Aufbau des Projekts

Die folgende Abbildung zeigt den Aufbau des Projekts:

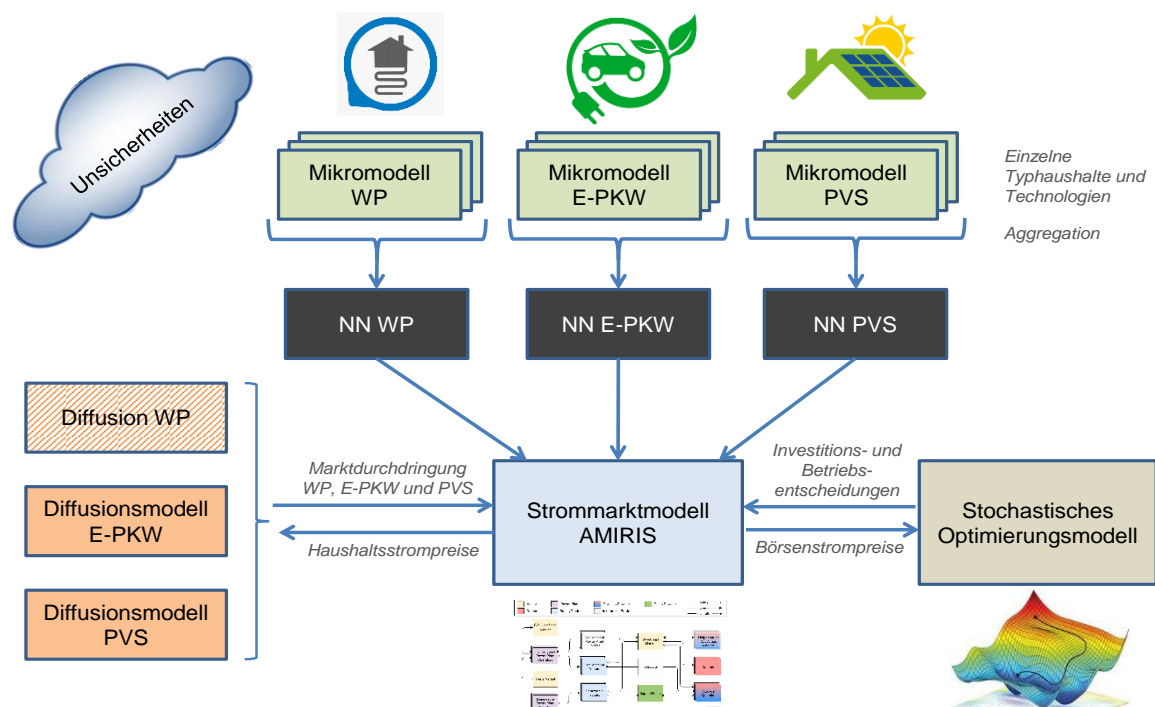


Abbildung 1. Aufbau des Projekts En4U und Modellkopplung

Das Projekt kann durch seine Modellkopplungen beschrieben werden. Auf der linken Seite in Abbildung 1 sind die drei vom KIT-IIP entwickelten Diffusionsmodelle (orange) zu sehen. Sie beschreiben quantitativ die erwartete Entwicklung der im Projekt betrachteten Technologien Wärmepumpen, E-Pkw und Photovoltaik-Anlagen mit Speicher für die Zukunft bis 2050. Dies geschieht

auf Haushaltsebene und wirtschaftlich optimiert. Diese Zahlen fließen als Marktdurchdringung in AMIRIS (blau) ein, und sind der Multiplikator für die ML-Modelle (schwarz). Die ML-Modelle wiederum werden über den Input dreier preis-optimierender Mikromodelle (grün) trainiert, die viele Trainingsdaten auf individueller Ebene (Haushalte) liefern. Die Aggregation dieser Modelle ergibt die jeweilige Gesamtnachfrage in Deutschland für jede Stunde eines bestimmten Jahres bis 2050 für jede der drei Technologien. Diese präzisen Bottom-up ML-Modelle werden als Agenten neben anderen Agenten in AMIRIS integriert.

Schließlich wird eine enge Modellkopplung zwischen dem Marktmodell AMIRIS und dem stochastischen Optimierungsmodell (SOM) vorgenommen. Um diese Hartkopplung zu automatisieren, wird eine dedizierte Software (RCE, siehe Abschnitt 6) verwendet. AMIRIS liefert Strompreise, Nachfrage und Systemkosten an das SOM, während das SOM auf Basis dieser *betriebswirtschaftlichen* Entwicklungen eine jährliche *volkswirtschaftliche* stochastische Optimierung des Kraftwerkparks vornimmt.

## 2.4 Aufbau dieses Berichts

Die Abschnitte 3 (DLR), 4 (KIT-IIP), 5 (KIT-IOR) und 6 (Modellkopplung) präsentieren alle gekoppelten Modelle jeweils in drei identischen Unterabschnitten pro Modell: im ersten Punkt wird das bereits vorhandene Modell vorgestellt, im zweiten Punkt werden im Detail die im Projekt erfolgten Weiterentwicklungen dargelegt, und im dritten Punkt werden die wichtigsten Punkte in einer Zusammenfassung gezeigt. Durch diese Struktur und die modellspezifischen Zusammenfassungen der erreichten Ergebnisse soll die Nachvollziehbarkeit des komplexen Workflows erhöht werden. Abschnitt 7 beschreibt die Datengrundlage, Abschnitt 8 die Ergebnisse pro Modell und insgesamt. Am Ende werden in den Abschnitten 9, 10 und 11 die Ergebnisse zusammengefasst, die Schlussfolgerungen diskutiert und die Verwendung der Zuwendung noch einmal aufgenommen.

# 3 Methodenentwicklung DLR: AMIRIS, Mikromodelle PVS, E-Pkw und Wärmepumpen, sowie ML-Modelle (DLR)

## 3.1 Weiterentwicklung des Simulationsmodells AMIRIS

### 3.1.1 Einführung in das Modell

Mit dem agentenbasierten Energiemarktmodell AMIRIS (*Agent-based Market model for the Investigation of Renewable and Integrated energy Systems*) werden energiepolitische Instrumente und Mechanismen zur Marktintegration erneuerbarer Energien und Flexibilitätsoptionen analysiert und bewertet.

Energiepolitische Instrumente können ihre beabsichtigte Wirkung nicht immer wie ursprünglich geplant erreichen. Auch werden sie teilweise von nicht beabsichtigten Effekten begleitet. Daher müssen bei der Ausgestaltung politischer Instrumente und der Rahmenbedingungen das Verhalten von Akteuren berücksichtigt werden. Hierfür bietet die agentenbasierte Modellierung einen passenden Ansatz, da hier die Akteure mit ihren Wahrnehmungen und Handlungsmustern im Zentrum der Modellierung stehen. Bei der Modellierung der Handlungen der Agenten (die den Akteuren in der Realität möglichst genau entsprechen) und ihrer Wechselwirkungen untereinander, wird auf Vorarbeiten durch intensive Akteursanalysen aufgebaut (z. B. durch Experteninterviews), um eine möglichst genaue Abbildung des realen Verhaltens zu ermöglichen.

Abbildung 2 enthält einen Überblick über die in AMIRIS modellierten Agenten sowie zugehörige Informations-, Energie-, und Zahlungsflüsse zwischen ihnen.

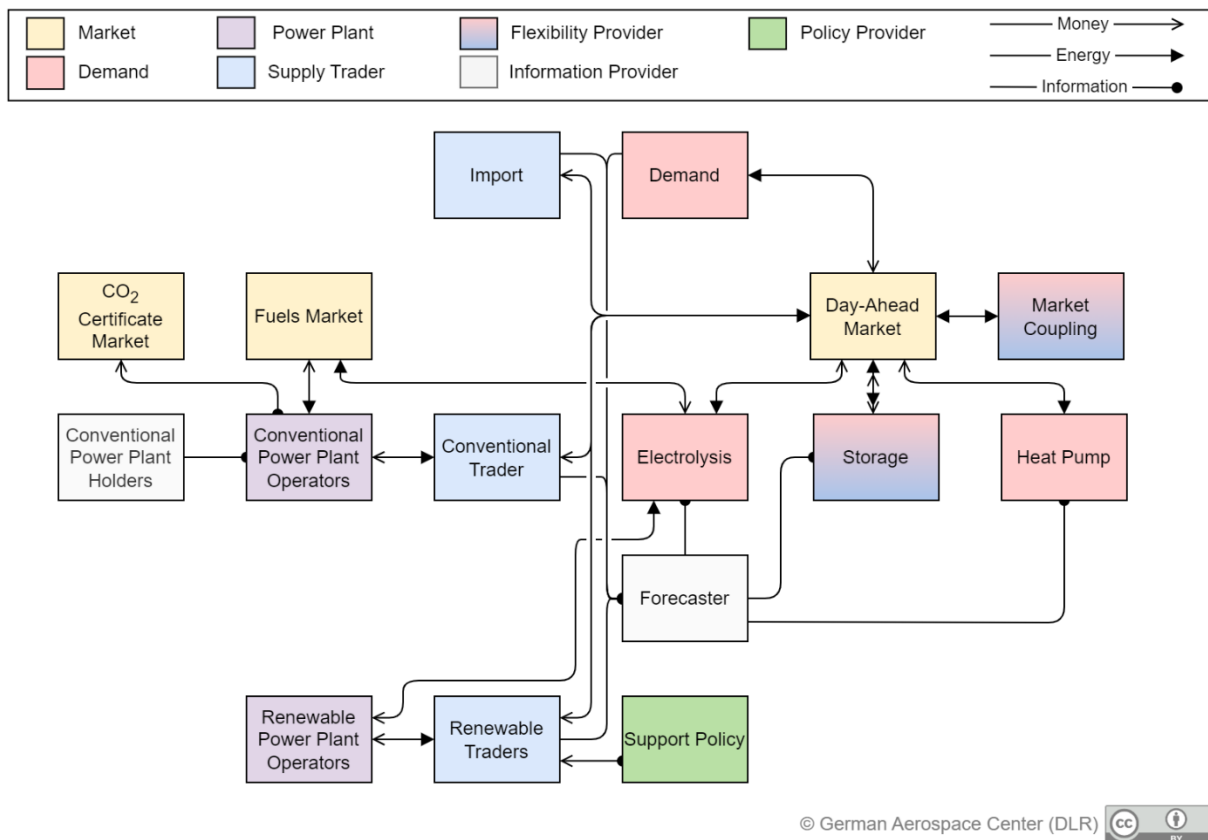


Abbildung 2. Modellstruktur AMIRIS

Die in AMIRIS als Agenten abgebildeten Akteure lassen sich in sechs Klassen einteilen: Kraftwerksbetreiber, Händler, Marktplätze, regulatorische Rahmenbedingungen, Nachfrager und Flexibilitätsanbieter. Kraftwerksbetreiber (lila) stellen Stromhändlern (hellblau) Produktionskapazitäten zur Verfügung, handeln im Modell aber nicht selbst an den Märkten (gelb). Den Handel und damit die Betriebsentscheidungen übernehmen Händler unter Verfolgung spezifischer Gebotsstrategien. Marktplätze verfolgen selbst keine Ziele, sondern dienen lediglich als Handelsplattformen unter verschiedenen Mechanismen (zum Beispiel Regularien und Market-Clearing).

Die regulatorischen Rahmenbedingungen legen den rechtlichen Rahmen z. B. für Förderinstrumente fest. Nachfrage-Agenten handeln am Strommarkt und platzieren preis- und zeitabhängige Gebote zur Deckung der Strombedarfe. Flexibilitätsanbieter wie z. B. Speicherbetreiber können ebenfalls direkt an den Märkten handeln, um auf Basis von Prognosen mittels Arbitrage Profite zu maximieren.

Simulationen mit AMIRIS ermöglichen so unter anderem die Untersuchung des Einflusses politischer Rahmenbedingungen auf Verhalten und Rentabilität von Energiemarktakteuren unter Berücksichtigung verschiedener Vermarktungspfade sowie die Quantifizierung des Einflusses sozio-ökonomischer Entscheidungsaspekte von Einzelakteuren auf die Energiemärkte, wie z. B. Strompreisentwicklungen.

Durch seine agentenbasierte und modulare Natur kann AMIRIS leicht erweitert oder modifiziert werden. Durch dessen High-Performance-Computing-Fähigkeit und rechenzeiteffiziente Entwicklung kann AMIRIS auch umfangreiche Agentensysteme in kurzer Zeit simulieren. Aktuell können mehrere Modelljahre in stündlicher Auflösung in weniger als einer Minute simuliert werden.

AMIRIS leistet seit 2010 Beiträge zum Verständnis emergenter Marktdynamiken und wird kontinuierlich verbessert und erweitert (Deissenroth et al. 2017; Schimeczek et al. 2023a; Schimeczek et al. 2023b). AMIRIS ist Open-Source und steht anderen Forschenden frei zur Verfügung (<https://gitlab.com/dlr-ve/esy/amiris/amiris>). AMIRIS basiert auf dem Framework zur agentenbasierten Energiesystemanalyse FAME, das ebenfalls offen der Forschungsgemeinde zur Verfügung gestellt wird (<https://gitlab.com/fame-framework>). Im Projekt wird AMIRIS zur Analyse der Haushaltstrategien bezüglich der Stromnachfrage eingesetzt.

### 3.1.2 Modellerweiterung

AMIRIS wurde im Projekt in dreierlei Hinsicht erweitert.

*Die erste Erweiterung* betrifft die Fähigkeit von AMIRIS, während der Laufzeit der Simulation externe Modelle über eine Schnittstelle aufzurufen und deren Ergebnisse dynamisch in der Simulation zu verwenden. Dazu wurde eine Struktur in AMIRIS geschaffen, die es Agenten ermöglicht, sogenannte „POST requests“ zu versenden und auf deren Antwort zu warten. Die vom externen Modell benötigten Daten werden dazu seitens AMIRIS in ein JSON Format gebracht. Diese Datenserialisierung von Java nach JSON erfolgt vollautomatisiert. Der gesamte Prozess zur Einbindung externer Modelle wurde zwecks Vereinfachung in die Hilfsklasse „UrlModelService“ ausgelagert und veröffentlicht (<https://gitlab.com/dlr-ve/esy/amiris/amiris/-/wikis/Classes/UrlModelService>).

Als Gegenstück der AMIRIS-Implementierung benötigen die externen Modelle eine HTTP-basierte Schnittstelle, die auf Anfragen wartet, Daten entgegennimmt und die Modellantwort an AMIRIS zurücksendet. Hier hat sich das quelloffene, auf Python basierende Framework FastAPI (<https://fastapi.tiangolo.com>) als besonders geeignet herausgestellt. Dieses ermöglicht es, auf einfache Weise HTTP-Schnittstellen an externe Modelle anzubinden: Hierzu werden nur wenige Zeilen Programmcode benötigt. Durch den HTTP-Standard sind Entwickler jedoch in der Wahl des Frameworks nicht eingeschränkt. Dutzende Alternativen sind verfügbar (z. B. *Django*, <https://www.djangoproject.com/>, oder *Flask*, <https://flask.palletsprojects.com/en/stable/>). Dies gewährt zukünftigen Entwicklungen und Forschern große Freiheiten bei der Wahl der Implementierung. Es muss erwähnt sein, dass diese Entscheidung auch einen Nachteil mit sich bringt: Da die Daten in ein unkomprimiertes Format serialisiert werden, ist der Overhead für die Übertragung der Daten zwischen AMIRIS und externem Modell recht groß. Folglich kann sich die Simulation von AMIRIS merklich verlangsamen, falls in jeder Simulationsstunde größere Datenmengen zwischen externem Modell und AMIRIS ausgetauscht werden müssen. Hinzu kommt natürlich auch die Rechenzeit der externen Modelle. In Summe steigt hierdurch die Ausführungszeit von AMIRIS in diesem Projekt von wenigen Sekunden auf einige Minuten an.

Die neue Fähigkeit zur Einbindung externer Modelle wird in diesem Projekt für die Vorhersage der Gesamtlast aus einzelnen Haushaltsprofilen durch neuronale Netze (siehe Abschnitt 3.5) verwendet. Dafür mussten einige Agenten in AMIRIS stark erweitert bzw. komplett neu entwickelt werden. Dies sind v. a. die Trader der drei analysierten Technologien, sowie deren Trading-Strategien:

- ML\_HouseholdPVTrader

- HeatPumpTrader
- FlexibilityTrader
- EndUserTariffStrategist
- ML\_PVBiddingStrategist
- ML\_EVBiddingStrategist
- ML\_EV\_Trader

Die zweite Erweiterung betrifft die Implementierung der Schnittstellenfähigkeit. Das betrifft die neu entwickelten Agenten ML\_HouseholdPVTrader, HeatPumpTrader und ML\_EVTrader und geschieht hauptsächlich in den neuen Methoden *requestPriceForecast*, *updatePriceForecast*, *prepareBids*, und *digestAwards*, für den ML\_BiddingStrategist in *getNetLoadPredictionInMWH*, *correctStorageOperation*, *updateStorage*, *updatePriceHistory*, *updateLoadHistory*, *getTimesMissingForecasts*, und *storeElectricityPriceForecast* – jeweils pro Technologie.

Eine Harmonisierung der Datenfelder der ML-Modelle und der Agenten in AMIRIS war ebenfalls notwendig, da die Inputdaten, die für das Training der ML-Modelle verwendet wurden, exakt den während der Simulation vorliegenden Daten der entsprechenden Agenten entsprechen müssen. Tabelle 1 zeigt diese Felder:

Tabelle 1. Übergabe-Variablen zwischen den ML-Modellen (E-Pkw und PVS) und AMIRIS

| Variablenname in AMIRIS                        | Beschreibung  | Modell      |
|--|---|-------------|
| serviceURL                                     | Schnittstelle zwischen AMIRIS und externem Server, der die Kommunikation sicherstellt | PVS + E-Pkw |
| Model ID                                       | ID zur eindeutigen Kennzeichnung des Modells  | PVS + E-Pkw |
| forecastPeriodInHours                          | Länge des Vorhersagezeitraums   | PVS + E-Pkw |
| LoadInMW                                       | Last in Megawatt  | PVS         |
| GenerationProfile                              | Hinter der Erzeugungsleistung liegendes Wetterprofil                                  | PVS         |
| aggregated_available_charging_power_cluster_MW | Zur Verfügung stehende Ladeleistung für das jeweilige Cluster der E-Pkw-Flotte        | E-Pkw       |
| aggregated_elec_consumption_cluster_MWH        | Verbrauch des E-Pkw-Clusters  | E-Pkw       |

---

Daneben gibt es weitere Parametrierungen, z. B. zum Speicher, der Strategie und der Businesslogik. Sie betreffen aber nicht den Austausch zwischen der Simulation und dem ML-Modell. Auf die Features, d. h. die Inputvariablen für das Training der neuronalen Netzwerke kommen wir in Abschnitt 3.5 zu sprechen.

*Die dritte Erweiterung* betrifft die Kopplung mit dem stochastischen Optimierungsmodell (SOM). Dafür muss AMIRIS in der Lage sein, Output für die dualen Werte (*dual values*) auszugeben. Während das SOM die langfristige überjährige Planung der Kraftwerke übernimmt, wird in AMIRIS die stündliche Markträumung mit diesen Inputdaten simuliert. Diese Kopplung geschieht über die Übermittlung der Systemkosten, der Marginalkosten, und der Elektrizitätspreise von AMIRIS an das SOM. Damit können die dualen Werte und die Optimierungsschnitte (*optimality cuts*) im SOM berechnet werden.

Die mathematischen Schritte hierfür und die technische Umsetzung können in der zugehörigen Publikation (siehe Abschnitt 11.2) im Detail nachgelesen werden (siehe auch Abschnitte 5 und 8.7).

Die Modellkopplung erfolgt auf technischer Ebene über die RCE- Software (siehe Abschnitt 6.2), auf Datenebene über gemeinsame Szenariendaten (siehe Abschnitt 7.2) und bezüglich der Vorhersagen der individuellen Haushaltsnachfrage über die Schnittstelle (siehe oben).

### 3.1.3 Zusammenfassung

AMIRIS (<https://gitlab.com/dlr-ve/esy/amiris/amiris>) hat damit fünf wesentliche Erweiterungen erfahren:

1. Neue Agenten
2. Neue Funktionalität dieser Agenten
3. Schnittstellenfähigkeit zu externen ML-Modellen
4. Implementierung der Schnittstelle selbst durch Harmonisierung der Daten
5. Implementierung der Weitergabe der Daten an das stochastische Optimierungsmodell, sodass duale Werte und Optimierungsschnitte berechnet werden können



### 3.2 Weiterentwicklung des Mikromodells Photovoltaik

Das Mikromodell Photovoltaik ist eines von drei Mikromodellen, die entwickelt wurden. Das Photovoltaik-Mikromodell simuliert die Energieinteraktionen von Haushalten mit PVS.

Durch die Optimierung der Betriebsentscheidungen von Haushalten mit PVS zielt dieses Mikromodell darauf ab, die gesamten Energiekosten zu minimieren, indem es Erzeugung, Verbrauch und Speicherung ausgleicht.

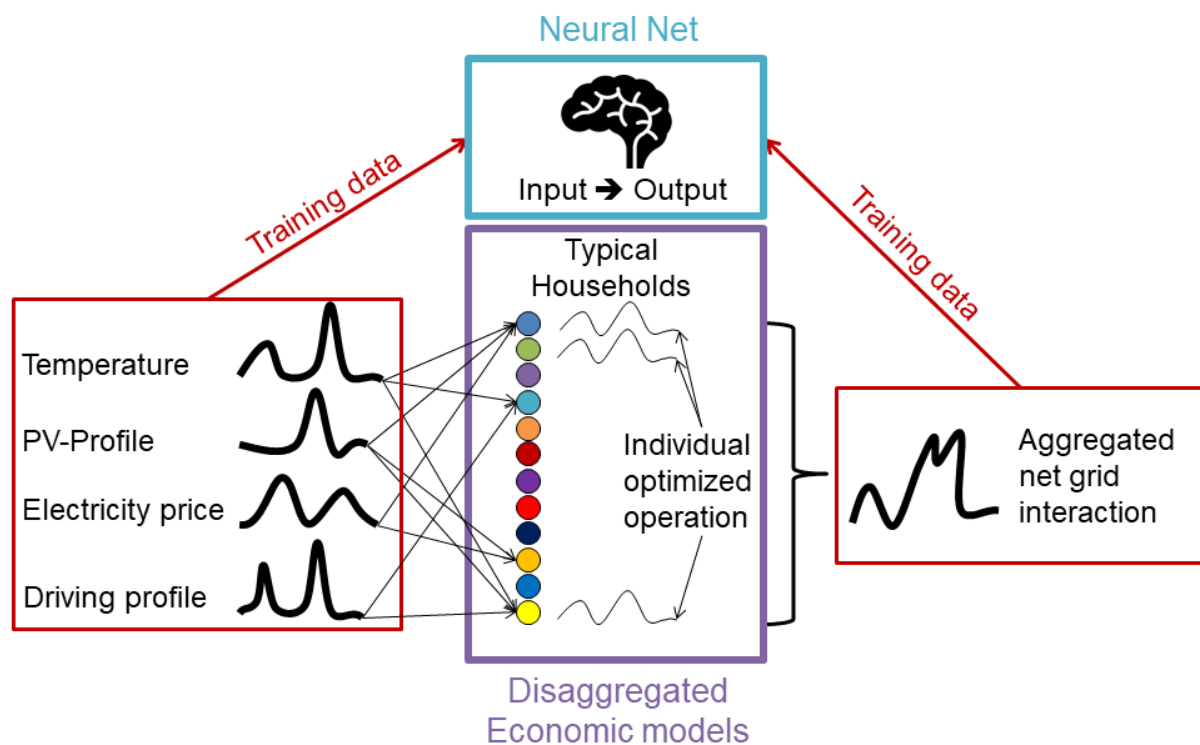


Abbildung 3. Aggregation der einzelnen Haushaltsentscheidungen durch maschinelles Lernen zur Vorhersage der Gesamtbelastung

Dieses Mikromodell, wie allen anderen Mikromodellen, dient als grundlegende Komponente zum Trainieren von Maschinenlernmodellen (ML), die die aggregierte Last von Tausenden von Haushalten unter verschiedenen Bedingungen wie unterschiedlichen Wetterjahren und Strompreismodellen vorhersagen (siehe Abbildung 3).

Das PVS-Optimierungsmodell ist Teil eines komplexeren Optimierungsmodells, das auch andere Haushaltsarten umfasst, wie z. B. Haushalte mit Wärmepumpen. Diese werden auf einer zweiten Ebene durch einen sogenannten *Community Aggregator* aggregiert und optimiert.

Details zu diesem Modell sind in Sarfarazi et al. (2020) zu finden. In diesem Projekt isolieren wir den PVS-Optimierungsteil als eigenständiges Modell. Um dies zu erreichen, verwendet das Photovoltaik-Mikromodell dynamische Programmierung, eine Methode, die speziell dafür entwickelt wurde, sequentielle Entscheidungsprobleme zu lösen, bei denen Entscheidungen zu einem Zeitpunkt die Ergebnisse in den folgenden Zeitpunkten beeinflussen. Diese Methode ist besonders effektiv, um die zeitlichen Abhängigkeiten zwischen PV-Systemen, Batterien und dem Stromnetz zu erfassen.

Die Optimierung basiert auf dem Bellman-Prinzip der Optimalität. Es besagt, dass eine optimale Strategie für den gesamten Zeitraum aus optimalen Teilstrategien für jedes kleinere Zeitintervall

besteht. Durch die iterative Lösung dieser Teilprobleme und das Verknüpfen ihrer Lösungen stellt das Modell sicher, dass jede lokale Entscheidung zur global optimalen Lösung für den gesamten Optimierungszeitraum beiträgt. Dieser Ansatz ermöglicht es dem Mikromodell, optimale Dispatch-Strategien für PVS-Haushalte effizient zu bestimmen und gleichzeitig die rechnerische Effizienz zu gewährleisten.

### 3.2.1 Beschreibung des PVS-Optimierungsproblems

Das Optimierungsproblem für das Photovoltaik-Mikromodell zielt darauf ab, die Kosten der Energieinteraktionen zu minimieren, während physikalische und betriebliche Einschränkungen eingehalten werden. Dabei sind die wichtigsten Komponenten des Problems:

- *Batteriebedingungen*
  - Die Lade- und Entladevorgänge der Batterie unterliegen Effizienzfaktoren.
  - Der Ladezustand (SOC) der Batterie muss jederzeit innerhalb vorgegebener Grenzen bleiben.
- *Optimierungsziel*
  - Das Ziel ist es, die gesamten Energiekosten zu minimieren, einschließlich der Kosten für Netzstrom und der Einnahmen aus der Einspeisung von überschüssigem Strom in das Stromnetz.

Die dynamische Programmierung diskretisiert das Optimierungsproblem sowohl über den Zeitrahmen als auch über den Zustandsraum, was die effiziente Berechnung von optimalen Strategien ermöglicht. Dieser Ansatz ist besonders effektiv, um die zeitlichen Abhängigkeiten der Speicheroperationen zu erfassen und die rechnerische Effizienz sicherzustellen.

### 3.2.2 Modellerweiterung

Die Implementierung der dynamischen Programmierung unterteilt den Zustandsraum in diskrete Intervalle, die den Ladezustand (SOC) der Batterie repräsentieren. Zu jedem Zeitpunkt definieren die Optimierungsbeschränkungen, wie Speicherkapazität, Energie-zu-Leistung-Verhältnis und Effizienzmindernungen, die zulässigen Zustände und Übergänge. Der Algorithmus berechnet iterativ die Kosten für den Übergang zwischen Zuständen, wobei die Beschränkungen eingehalten werden.

Der Optimierungsprozess umfasst:

- *Rückwärtsberechnung*: Beginnend vom letzten Zeitschritt ( $t$ ) arbeitet die Optimierung rückwärts, um die "Cost-to-Go" für jeden möglichen Zustand zu jedem Zeitpunkt zu berechnen. Am letzten Zeitpunkt werden die Kosten direkt basierend auf dem unmittelbaren Zustand des Systems berechnet (z. B. Batteriezustand, Nachfrage, PV-Erzeugung). Beim Zurückrechnen bewertet der Algorithmus, wie sich Aktionen zu früheren Zeitpunkten auf den Zustand des Systems zu späteren Zeitpunkten auswirken, und stellt sicher, dass zu jedem Zeitpunkt die beste Entscheidung getroffen wird. Dies ermöglicht es dem Modell, zukünftige Zustände zu berücksichtigen, während es rückwärts rechnet.
- *Vorwärtssimulation*: Nachdem die optimalen Kosten für alle Zustände zu jedem Zeitpunkt in der Rückwärtsphase berechnet wurden, beginnt die Vorwärtssimulation. Mithilfe dieser vorab berechneten Kosten simuliert der Algorithmus den Verlauf der Zustände ab dem ersten Zeitpunkt und wählt zu jedem Schritt die optimale Entscheidung, um die Gesamtkosten der Energie zu minimieren. Dieser Schritt bestimmt die tatsächliche Reihenfolge von Aktionen, die zur optimalen Lösung für den gesamten Optimierungszeitraum führt.

### 3.2.3 Zusammenfassung

Das aus dem vorhandenen AMIRIS-PV-Agenten abgeleitete, und jetzt völlig unabhängige PVS-Mikromodell ist in der Lage, für gegebene Wetter- und Strompreiszeitreihen den optimalen Betrieb von PV-Anlagen mit Speichern auf Haushaltsebene abzubilden. Es wird in Kürze in das offene AMIRIS-Simulationsmodell (<https://gitlab.com/dlr-ve/esy/amiris/amiris>) integriert. Verbunden mit der Kapitalwertanalyse für jede Haushaltsgruppe von PV und PVS (siehe Abschnitt 4.3) und des Diffusionsmodells für PV (siehe Abschnitt 4, 7.6 & 8.6) ist eine präzise Fortschreibung des kostenoptimalen PVS-Betriebs in Deutschland bis 2050 auf der Haushaltsebene möglich.

## 3.3 Weiterentwicklung des Mikromodells Wärmepumpen

### 3.3.1 Einführung in das Modell

Das Mikromodell Wärmepumpen ist ein Bottom-up-Modell, mit dem der Einsatz von Wärmepumpen in Wohngebäuden für die Raumheizung und die Erzeugung von Trinkwarmwasser optimiert werden kann. Unter Verwendung dynamischer Strompreise, Wetterdaten, Warmwasserzapfprofile und Parametern für das thermische Verhalten von Typgebäuden sowie für Wärmepumpen als Input-Daten berechnet das Modell den aggregierten *kostenminimalen* Netzstromverbrauch für repräsentative Einfamilienhäuser in Deutschland in einer viertelstündlichen Auflösung. Das Modell berücksichtigt den thermischen Komfort der Nutzer durch die Berücksichtigung variabler Heiztemperatursollwerte.

### 3.3.2 Modellerweiterung

Vor Projektbeginn stand ein stark vereinfachtes Wärmepumpen-Betriebsmodell innerhalb von AMIRIS zur Verfügung, das in Java programmiert war. Das ursprüngliche Ziel innerhalb von En4U bestand darin, dieses aus AMIRIS zu extrahieren und für das Training von neuronalen Netzen zu ertüchtigen. Im Projektverlauf zeigte sich jedoch, dass das vereinfachte Modell für die weitere Betrachtung von flexiblen Wärmepumpen nicht ausreichend ist. Dies ist auf folgende Gründe zurückzuführen:

- Das vereinfachte Modell berücksichtigt keine Trinkwarmwasser-Bereitung.
- Thermisches Gebäudeverhalten kann im vereinfachten Modell nur durch ein einfaches 1R1C-Netzwerk simuliert werden, welches jedoch Defizite hinsichtlich der Genauigkeit aufweist (Sperber et al. 2020). Komplexere und präzisere Netzwerkstrukturen lassen sich mit dem verwendeten Dynamic-Programming-Algorithmus jedoch nicht abbilden.
- Die Struktur lässt eine flexible Parametrierung einer Vielzahl von Typhaushalten nicht zu.

Aus den genannten Gründen wurde das bisherige, vereinfachte Modell durch eine Neuentwicklung eines eigenständigen Wärmepumpen-Einsatzmodells in GAMS abgelöst.

Das Ziel des Modells ist die Minimierung der Strombezugskosten für ein Portfolio von Wärmepumpen über einen Zeithorizont  $T$ . Diese Kosten setzen sich aus dem dynamischen Strompreis,  $p_t^{RTP}$ , und dem aggregierten Netzstrombezug,  $e_t^{agg}$ , zusammen (Eq. 1)

$$\text{Minimiere } \left( \sum_{t=1}^T (p_t^{RTP} \times e_t^{agg}) \times \Delta t \right) \quad \text{Eq. 1}$$

Der aggregierte Stromverbrauch aus dem Netz,  $e_t^{agg}$ , ist die Summe des Netzstromverbrauchs aller Wärmepumpen-Typen  $hp$  in allen betrachteten Gebäudetypen  $n$  zu jedem Zeitschritt  $t$ . Er besteht aus

zwei Komponenten: die für die Raumheizung benötigte Menge,  $e_{hp,n,t}^{SH}$ , und die für die Warmwasserbereitung,  $e_{hp,n,t}^{DHW}$  (Eq. 2).

$$e_t^{agg} = \sum_{hp} \sum_n (e_{hp,n,t}^{SH} + e_{hp,n,t}^{DHW}) \quad \forall t \quad \text{Eq. 2}$$

Im Modell wird davon ausgegangen, dass Wärmepumpen stufenlos regelbar sind und ihr Stromverbrauch durch ihre installierte Kapazität  $Pel_{hp,n}^{SH}$  bzw.  $Pel_{hp,n}^{DHW}$  begrenzt ist (Eq. 3 und Eq. 4).

$$0 \leq e_{hp,n,t}^{SH} + pv_{hp,n,t}^{SH} \leq Pel_{hp,n}^{SH} \quad \forall hp, n, t \quad \text{Eq. 3}$$

$$0 \leq e_{hp,n,t}^{DHW} + pv_{hp,n,t}^{DHW} \leq Pel_{hp,n}^{DHW} \quad \forall hp, n, t \quad \text{Eq. 4}$$

Flexibilität kann auf zwei Wegen bereitgestellt werden. Erstens kann die Raumlufttemperatur  $Ti_{hp,n,t}$  innerhalb der vorgegebenen Grenzen für das Minimum ( $Ti_{hp,n,t}^{min}$ ) und das Maximum ( $Ti_{hp,n,t}^{max}$ ) variieren (Eq. 5), wobei sichergestellt werden muss, dass ihr Durchschnitt gleich einer Durchschnittstemperatur  $Ti_{hp,n}^{avg}$  über den Zeithorizont ist (Eq. 6). Zweitens kann die Temperatur des Warmwasserspeichers,  $Ttes_{hp,n,t}$ , zwischen den vorgegebenen Grenzen für das Minimum,  $Ttes_{hp,n,t}^{min}$ , und das Maximum,  $Ttes_{hp,n,t}^{max}$ , schwanken (Eq. 7).

$$Ti_{hp,n,t}^{min} \leq Ti_{hp,n,t} \leq Ti_{hp,n,t}^{max} \quad \forall hp, n, t \quad \text{wenn} \quad \sum_{t=1}^T Ta_t / T \leq Ta_n^{limit} \quad \text{Eq. 5}$$

$$\sum_{t=1}^T Ti_{hp,n,t} / T = Ti_{hp,n}^{avg} \quad \forall hp, n, t \quad \text{wenn} \quad \sum_{t=1}^T Ta_t / T \leq Ta_n^{limit} \quad \text{Eq. 6}$$

$$Ttes_{hp,n,t}^{min} \leq Ttes_{hp,n,t} \leq Ttes_{hp,n,t}^{max} \quad \forall hp, n, t \quad \text{Eq. 7}$$

Die Einschränkungen in Bezug auf die Temperatur werden außerhalb der festgelegten Heizperiode gelockert. Wir definieren die Heizperiode als die Zeit, in der die Durchschnittstemperatur über den Zeithorizont hinweg über einer vom Gebäudetyp abhängigen Heizgrenztemperatur,  $Ta_n^{limit}$ , liegt. Die Raumlufttemperatur kann außerhalb der Heizperiode gegen die vorgegebenen Grenzwerte verstoßen, um die passive Erwärmung durch solare Gewinne oder hohe Umgebungstemperaturen widerzuspiegeln (Eq. 5 und Eq. 6).

Zur Berechnung des Raumwärmebedarfs und der entsprechenden Innenraumtemperaturen von Gebäuden innerhalb des GAMS-Modells setzen wir eine Reihe von validierten Bottom-up-Modellen der Gebäudethermodynamik ein, die in Sperber et al. (2020) entwickelt wurden. Die Modelle basieren auf thermischen RC-Netzwerken (3R2C und 4R3C), um Transmissions- und Lüftungsverluste, solare und interne Wärmegewinne sowie die thermische Trägheit zu berücksichtigen. Dabei werden die Umgebungstemperatur und die Sonneneinstrahlung als Eingangszeitreihen verwendet.

Die Modelle umfassen zwölf typische deutsche Einfamilienhäuser mit jeweils drei Dämmzuständen. Diese unterscheiden sich hinsichtlich des Alters, der Größe, der Baumaterialien sowie der

Heizungsverteilungssysteme. Diese Daten repräsentieren den aktuellen Bestand an Einfamilienhäusern in Deutschland.

Der Strombedarf für die Warmwasserbereitung wird auf der Grundlage der angegebenen Warmwasserentnahmeprofile auf Gebäudeebene gemäß dem offenen Tool *DHW calc, Version 2.02b – Tool for the Generation of Domestic Hot Water (DHW) Profiles on a Statistical Basis* (Jordan et al. 2018) berechnet. Es wird davon ausgegangen, dass jedes Gebäude mit einem Warmwasserspeicher ausgestattet ist, der dazu dient, Energie zu speichern, um den Bedarf zu einem bestimmten Zeitpunkt zu decken.

Eine detaillierte Modellbeschreibung ist der Publikation zu entnehmen, die im Rahmen von En4U entstanden ist (Sperber et al. 2024).

Da die Diffusionsmodellierung von Wärmepumpen nicht Gegenstand von En4U ist und entsprechend keine Umfrageergebnisse zu Typhaushalten mit Wärmepumpen vorliegen, wurde das Mikromodell Wärmepumpen für die Anwendung im Projekt auf Basis eigener Recherchen und Annahmen parametrisiert. Diese Angaben sind ebenfalls in der genannten Publikation zu finden.

### 3.3.3 Zusammenfassung

Das entwickelte Mikromodell für Wärmepumpen (<https://zenodo.org/records/14191160>) ermöglicht die Ermittlung des kostenminimalen Einsatzes von Wärmepumpen in Wohngebäuden unter Berücksichtigung dynamischer Strompreise. Im Rahmen der Projektlaufzeit wurde das bestehende Modell vollständig neu in GAMS geschrieben und maßgeblich weiterentwickelt, um das thermische Gebäudeverhalten besser abzubilden und erstmals auch die Trinkwarmwasserbereitung zu berücksichtigen. Darüber hinaus ermöglicht die neue Modellstruktur eine flexiblere Parametrierung über CSV-Inputtabellen.

## 3.4 Weiterentwicklung des Mikromodells Elektromobilität

### 3.4.1 Einführung in das Modell

Zukünftige Flotten elektrisch angetriebener Fahrzeuge sind sowohl Chancen als auch Risiken für Energiesysteme. Auf der einen Seite erfordert eine Elektrifizierung des Verkehrs einen ausgeweiteten Kraftwerkspark, auf der anderen Seite können Batterien eine Flexibilitätsoption für das Stromsystem darstellen. Die genaue Beschreibung der Stromnachfrage zukünftiger elektrischer Plug-in-Fahrzeugflotten ist eine Voraussetzung für die Modellierung sektorengekoppelter Energiesysteme und die Bereitstellung politikrelevanter Erkenntnisse.

Das Modell `venco.py` berechnet Randbedingungen für das Ladeverhalten und Vehicle-to-Grid Potenziale basierend auf Mobilitätsdaten und techno-ökonomischen Annahmen (Miorelli et al. 2024 preprint). Es wurde bisher auf die deutsche Verkehrserhebung "Mobilität in Deutschland" angewendet, um den Einfluss des Nutzerverhaltens auf das zukünftige Lastverschiebepotenzial und dessen Auswirkungen auf das deutsche Stromsystem zu untersuchen. Das Modell ist öffentlich zugänglich unter: <https://gitlab.com/dlr-ve/esy/vencopy/vencopy>.

Der Prozess zur Erstellung von Lastprofilen für Elektrofahrzeuge in den jeweiligen Haushaltclustern im En4U-Projekt umfasst vier Schritte. Erstens wird der MiD-Datensatz („Mobilität in Deutschland“ - die deutsche nationale Verkehrserhebung) gefiltert, um Fahrzeugfahrten zu isolieren, die den beiden Haushaltclustern mit Elektrofahrzeugen zugeordnet sind (Eggs et al. 2018). Diese Fahrten werden mithilfe sozioökonomischer Variablen in dem MiD-Datensatz isoliert. Zweitens wird für jede dieser

Fahrtenkombinationen das Modell `venco.py` ausgeführt, um den Strombedarf und die Ladeflexibilität für jedes Haushaltscluster zu berechnen. Anschließend wird jedes Lastprofil mit einem Ein-Tages-Vorausschauansatz basierend auf dem Strompreis optimiert. Schließlich werden die Lastprofile für jedes Cluster anhand des Haushaltsdiffusionsmodells hochskaliert.

### 3.4.2 Modellerweiterung

#### 3.4.2.1 E-Pkw-Cluster

Die Datenerhebung der MiD-Umfrage fand in Deutschland von Mai 2016 bis September 2017 statt. Insgesamt wurden 316.361 Personen aus 156.420 Haushalten befragt, was der deutschen Bevölkerung zu der damaligen Zeit entspricht (etwa 41 Millionen Haushalte und 82 Millionen Individuen). Für die Analyse berücksichtigen wir nur Autofahrten mit verfügbaren Abfahrts- und Ankunftszeiten. Passagierfahrten werden ausgeschlossen, um eine doppelte Zählung zu vermeiden, da die meisten Autofahrten als Passagier mit einem anderen Haushaltsmitglied als Fahrer durchgeführt werden.

Zusätzlich zu den Fahrtdaten, wie Start- und Endzeit der Fahrt, zurückgelegte Entfernung und Wochentag, enthält der MiD-Datensatz zahlreiche sozioökonomische Variablen, die sich auf die Haushalte beziehen, zu denen die Fahrten gehören. Durch die Nutzung dieser zusätzlichen sozioökonomischen Variablen der Haushalte ist es möglich, die deutsche nationale Verkehrserhebung so zu filtern, dass repräsentative Mobilitätsmuster für die beiden spezifischen Haushaltscluster mit Elektrofahrzeugen (Cluster 2 und Cluster 14) erstellt werden können. Eine Übersicht der im MiD-Datensatz verwendeten Variablen und deren Beziehung zu den Merkmalen der Haushaltscluster ist in der untenstehenden Tabelle dargestellt.

*Tabelle 2. Mapping von MiD-Variablen zu Haushaltscluster-Merkmalen im En4U-Projekt.*

| <b>Variable</b>     | <b>MiD (B2 Wege Datensatz)</b>                  | <b>En4U-Projekt</b>           | <b>Mapping MiD<br/>→ En4U-<br/>Projekt</b> |
|---------------------|---|-------------------------------|--|
| Beschäftigung       | <b>Tätigkeit der Person (taet)</b>              | <b>EMP (Beschäftigung)</b>    | 1 → 4-6                                    |
|                     | 1 berufstätig                                   | 1 = Schüler*in                | 2 → 1-3                                    |
|                     | 2 Schüler(in), Student(in),<br>Auszubildende(r) | 2 = In Ausbildung             |  |
|                     | 3 Hausfrau/-mann                                | 3 = Student*in                | 3 → 7                                      |
|                     | 4 Rentner(in)/Pensionär(in)                     | 4 = Angestellte*r             | 4 → 9                                      |
|                     | 5 sonstiges                                     | 5 = Beamte*r                  | 5 → -                                      |
|                     | 9 keine Angabe                                  | 6 = Selbstständig             |  |
|                     |   | 7 = Arbeitslos/Arbeit suchend |  |
|                     |   | 9 = Rentner*in                |  |
| Gebäudetyp          | <b>Gebäudetyp (haustyp)</b>                     | <b>BUI (Gebäudetyp)</b>       | 1 → 1-3                                    |
|                     | 1 Ein- bis Zweifamilienhaus                     | 1 = Freistehendes             | 2-3 → 4                                    |
|                     | 2 Mehrfamilienhaus                              | Einfamilienhaus               |  |
|                     | 3 Geschosswohnungsbau                           | 2 = Doppelhaushälfte          |  |
|                     | 4 sonstiges                                     | 3 = Reihenhaus                |  |
| 95 nicht zuzuordnen | 4 = Wohnung in<br>Mehrfamilienhaus              |                               |  |
| Altersgruppe        | <b>Altersgruppe (alter_gr5)</b>                 | <b>AGE (Alter)</b>            | 1-4 → 2                                    |
|                     | 1 = 0-4 Jahre                                   | 2 = unter 25 Jahre            | 5-6 → 4                                    |
|                     | 2 = 4-9 Jahre                                   | 4 = 25 bis 35 Jahre           | 7-8 → 5                                    |

|                                 |   |   |                 |
|---------------------------------|---|---|-----------------|
|                                 | 3 = 10-17 Jahre   | 5 = 35 bis 45 Jahre   | 9-10 → 6        |
|                                 | 4 = 18-24 Jahre   | 6 = 45 bis 55 Jahre   | 11-12 → 9       |
|                                 | 5 = 25-29 Jahre   | 9 = 55 bis 65 Jahre   | 13-14 → 11      |
|                                 | 6 = 30-34 Jahre   | 11 = 65 bis 75 Jahre  | 15 → 12         |
|                                 | 7 = 35-39 Jahre   | 12 = 75 Jahre oder älter  |                 |
|                                 | 8 = 40-44 Jahre   |   |                 |
|                                 | 9 = 45-49 Jahre   |   |                 |
|                                 | 10 = 50-54 Jahre  |   |                 |
|                                 | 11 = 55-59 Jahre  |   |                 |
|                                 | 12 = 60-64 Jahre  |   |                 |
|                                 | 13 = 65-69 Jahre  |   |                 |
|                                 | 14 = 70-74 Jahre  |   |                 |
|                                 | 15 = 75 Jahre und älter   |   |                 |
|                                 | 99 keine Angabe   |   |                 |
| <b>Bildungsstand</b>            | <b>Bildungsabschluss (P_BIL)</b>  | <b>EDU (Formale Bildung)</b>  |                 |
|                                 | 1 = (noch) kein Abschluss   | 1 = Schule beendet ohne Abschluss                                       | 1 + 9 → 1       |
|                                 | 2 = Volks- oder Hauptschule, POS 8. Klasse                                      | 9 = Noch Schüler  | 2 → 3           |
|                                 | 3 = mittlere Reife, Realschulabschluss, POS 10. Klasse                          | 3 = Volks-, Hauptschulabschluss, Quali                                  | 3 → 4           |
|                                 | 4 = Fachhochschulreife, Abitur, EOS 12. Klasse bzw. Berufsausbildung mit Abitur | 4 = Mittlere Reife, Realschul- oder gleichwertiger Abschluss            | 4 → 6 + 7       |
|                                 | 5 = Fachhochschul- oder Universitätsabschluss                                   | 5 = Abgeschlossene Lehre  | 5 → 8           |
|                                 | 6 = anderer Abschluss   | 6 = Fachabitur, Fachhochschulreife                                      | 3+6 → 5         |
|                                 | 9 = keine Angabe  | 7 = Abitur, Hochschulreife  |                 |
|                                 | 206 = Erwachsener ab 14 Jahre (proxy)   | 8 = Fachhochschul-/Hochschulabschluss                                   |                 |
| <b>Sozioökonomischer Status</b> | <b>Ökonomischer Status des Haushalts (oek_status)</b>                           | <b>INC (Einkommen: monatliches Nettoeinkommen der Person)</b>           |                 |
|                                 | 1 = sehr niedrig  | 1 = unter 1000€   | 1 → 1-2         |
|                                 | 2 = niedrig   | 2 = 1000€ bis unter 1500€   | 2 → 3           |
|                                 | 3 = mittel  | 3 = 1500€ bis unter 2000€   | 3 → 4-5         |
|                                 | 4 = hoch  | 4 = 2000€ bis unter 2500€   | 4 → 6-7         |
|                                 | 5 = sehr hoch   | 5 = 2500€ bis unter 3000€   | 5 → 8           |
|                                 |   | 6 = 3000€ bis unter 4000€   |                 |
|                                 |   | 7 = 4000€ bis unter 5000€   |                 |
|                                 |   | 8 = 5000€ und mehr  |                 |
| <b>Bundesland</b>               | <b>Bundesland (BLAND)</b>   | <b>REG (Region)</b>   |                 |
|                                 | 1 Schleswig-Holstein  | 1 = Süden (Bayern, Baden-Württemberg, Saarland)                         | 8-10 → 1        |
|                                 | 2 Hamburg   | 2 = Mitte (Thüringen, Hessen, Sachsen, Sachsen-Anhalt, Rheinland-Pfalz) | 6-7 + 14-16 → 2 |
|                                 | 3 Niedersachsen   |   | 1-5 + 11-13 → 3 |
|                                 | 4 Bremen  |   |                 |
|                                 | 5 Nordrhein-Westfalen   |   |                 |
|                                 | 6 Hessen  |   |                 |

|                |  |   |         |
|----------------|--|---|---------|
|                | 7 Rheinland-Pfalz  | 3 = Norden (Hamburg, Bremen,              |         |
|                | 8 Baden-Württemberg                                      | Niedersachsen, Schleswig-                 |         |
|                | 9 Bayern   | Holstein, Mecklenburg-                    |         |
|                | 10 Saarland  | Vorpommern, Brandenburg,                  |         |
|                | 11 Berlin  | Berlin, Nordrhein-Westfalen)              |         |
|                | 12 Brandenburg   |   |         |
|                | 13 Mecklenburg-Vorpommern                                |   |         |
|                | 14 Sachsen   |   |         |
|                | 15 Sachsen-Anhalt  |   |         |
|                | 16 Thüringen   |   |         |
| Haushaltsgröße | <b>Haushaltsgröße in Gruppen (hhgr_gr2)</b>              | <b>HHS (Haushaltsgröße)</b>               |         |
|                | 1 = 1  | 1 = 1                                     | 1 → 1   |
|                | 2 = 2  | 2 = 2                                     | 2 → 2   |
|                | 3 = 3  | 3 = 3                                     | 3 → 3   |
|                | 4 = 4 und mehr   | 4 = 4                                     | 4 → 4-5 |
|                |  | 5 = 5 und mehr                            |         |
| Siedlungstyp   | <b>BBSR siedlungsstruktureller Kreistyp 2015 (SKTYP)</b> | <b>LOC (Wohnsitz Größe)</b>               |         |
|                | 1 = kreisfreie Großstadt                                 | 1 = Landgemeinde (unter 5.000 Einwohnern) | 4 → 1   |
|                | 2 = städtischer Kreis                                    | 2 = Kleinstadt (unter 20.000 Einwohner)   | 3 → 2   |
|                | 3 = ländlicher Kreis mit Verdichtungsansätzen            | 3 = Mittelstadt (unter 100.000 Einwohner) | 2 → 3   |
|                | 4 = dünn besiedelter ländlicher Kreis                    | 4 = Großstadt (ab 100.000 Einwohner)      | 1 → 4   |

Das Mapping der MiD-Daten (Mobilität in Deutschland) auf das En4U-Projekt erfordert eine Zuordnung relevanter Variablen und Konzepte aus der nationalen Mobilitätsstudie zu den spezifischen Anforderungen des En4U-Projekts, insbesondere im Hinblick auf die Mobilitätsmustern.

Als Ergebnis konnten die zwei Haushaltscluster mit Elektrofahrzeugen durch die Berücksichtigung der folgenden Variablen definiert werden:

Tabelle 3. Zusammenfassung der Merkmale von Haushaltsclustern mit Elektrofahrzeugen.

| Haushaltscluster<br>En4U-Projekt | Variablen |     |     |     |     |     |     |     |
|----------------------------------|-----------|-----|-----|-----|-----|-----|-----|-----|
|                                  | EMP       | BUI | AGE | EDU | INC | REG | HHS | LOC |
| Cluster 2                        | 4         | 1   | 4   | 8   | 8   | 3   | 5   | 1   |
| Cluster 14                       | 4         | 3   | 4   | 5   | 4   | 3   | 4   | 4   |

Da venco.py den direkten Zugriff auf zusätzliche Umfragedaten ermöglicht, wie zum Beispiel Haushaltsgröße, Einkommen, Alter und geografische Region, können Fahrzeugprofile mit spezifischen



Haushaltstypen verknüpft werden. Auf diese Weise ist es möglich, nur Fahrten auszuwählen, die den spezifischen Merkmalen dieser beiden Haushaltscluster entsprechen, und repräsentative Profile für Elektrofahrzeuge zu erstellen. Die untenstehende Abbildung zeigt die fünf zentralen Bausteine des Modells `venco.py`.

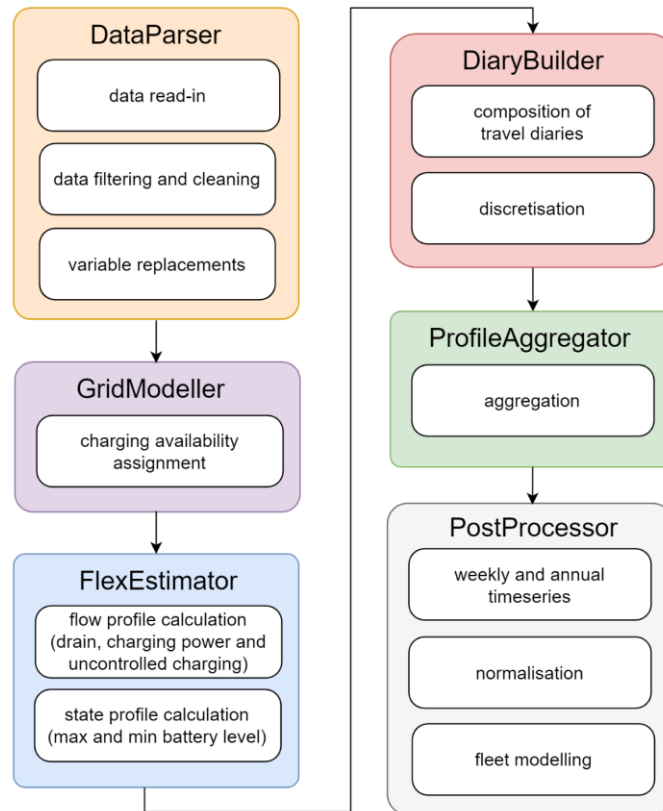


Abbildung 4. Struktur des Modells `venco.py` (Miorelli et al. 2024 preprint).

Um repräsentative Profile für jedes Cluster zu erstellen, musste das Modell angepasst werden, insbesondere im Hinblick auf die Klasse „DataParser“. Das Modell wurde dann iterativ ausgeführt, um jährliche Profile für jedes der Haushaltscluster zu generieren.

Wichtige Eingabedaten für das Modell sind technische Parameter des Fahrzeugs, wie die Batteriekapazität, der spezifische Stromverbrauch und die Verfügbarkeit der Ladeinfrastruktur. Die angenommenen Werte für diese Eingabedaten sind in der untenstehenden Tabelle zusammengefasst.

Tabelle 4. Übersicht der Modellparameter von `venco.py`

| Parameter                   | Wert | Einheit | Beschreibung   |
|-----------------------------|------|---------|--|
| Batteriekapazität           | 50   | kWh     | Maximale Speicherkapazität der Fahrzeugbatterie.       |
| Start- und Endbatteriestand | 25   | kWh     | Batteriestand zu Beginn und Ende der Jahressimulation. |

| Parameter                     | Wert  | Einheit                | Beschreibung   |
|-------------------------------|---|------------------------|--|
| Elektrischer Verbrauch        | 18  | kWh/100 km             | Energieverbrauch des Fahrzeugs pro 100 km.   |
| Maximaler Ladezustand (SoC)   | 0,97  | -                      | Obergrenze des Ladezustands der Batterie.  |
| Minimaler Ladezustand (SoC)   | 0,15  | -                      | Untergrenze des Ladezustands der Batterie.   |
| Zeitliche Auflösung           | 15  | Minuten                | Zeitintervall der Simulation.  |
| Verfügbarkeit des Stromnetzes | Fahren: 0: 1<br>Zuhause: 3.6: 0.4, 11: 0.4, 22: 0.1, 0: 0.1<br>Arbeit: 11: 0.2, 22: 0.2, 0: 0.6<br>Schule: 11: 0, 22: 0, 0: 1<br>Einkaufen: 11: 0.2, 22: 0.2, 0: 0.6<br>Freizeit: 11: 0.2, 22: 0.2, 0: 0.6<br>Sonstiges: 11: 0.2, 22: 0.2, 0: 0.6 | Wahrscheinlichkeit: kW | Wahrscheinlichkeiten für jede Standortkategorie basierend auf Zweck und Kapazität. |

Die Modellergebnisse umfassen Energienachfrage zum Fahren, Ladeleistungsprofile, minimale und maximale Batterieniveaus sowie unkontrollierte Ladeprofile, sowohl auf der Ebene einzelner Fahrzeuge, als auch auf Flottenebene. Die ersten vier Profile können als beschränkende Randbedingungen in anderen Modellen verwendet werden, um optimale Ladestrategien für die Fahrzeuge zu bestimmen. Auf diese Weise repräsentieren sie eine endogene Nachfrage von Elektrofahrzeugen. Das letzte Profil simuliert hingegen einen Fall, in dem das Laden unkontrolliert erfolgt und die Fahrzeuge laden, sobald eine Lademöglichkeit verfügbar ist. Die generische Natur der resultierenden Profile des Modells ermöglicht deren Einsatz zur Beantwortung einer Vielzahl von Forschungsfragen in unterschiedlichen Modellen, wie beispielsweise Energiesystem-optimierungsmodellen oder agentenbasierten Strommarktmodellen.

### 3.4.2.2 Preisbasierte Optimierung

Ein zusätzliches, preisbasierendes Optimierungsmodell wurde entwickelt, um den kostenminimalen Ladevorgang von Elektrofahrzeugen unter Berücksichtigung dynamischer Strompreise zu optimieren. Dabei werden die Ergebnisse des `venco.py`-Modells, wie Energienachfrageprofile, Ladeleistungsprofile sowie minimale und maximale Batterieniveaus, als Randbedingungen genutzt.

Die Zielfunktion ist die Minimierung der Ladekosten und wird definiert als:

$$\min \sum_{t=t_0}^{t_0+T} c(t) \cdot l(t) \cdot \Delta t$$

wobei  $t$  den diskreten Zeitschritt darstellt,  $t_0$  den aktuellen Zeitschritt zu Beginn des rollierenden Horizonts repräsentiert,  $T$  den Zeithorizont für die Optimierung angibt, der auf ein Jahr festgelegt ist,  $c(t)$  den Strompreis oder die Kosten zum Zeitpunkt  $t$  bezeichnet,  $l(t)$  die Last zum Zeitpunkt  $t$  repräsentiert, und  $\Delta t$  die Dauer eines einzelnen Zeitschritts darstellt.

Das Ziel der Optimierung ist es, die Gesamtkosten über den Zeithorizont zu minimieren, indem die Last in jedem Zeitschritt unter Berücksichtigung der zeitabhängigen Strompreise optimiert wird. Die Zielfunktion bewertet die Ladekosten über das rollierende Zeitfenster  $[t_0, t_0 + T]$ . Nach der Lösung für das aktuelle Zeitfenster verschiebt sich der Horizont nach vorne (z. B.  $t_0 \rightarrow t_0 + 1$ ), und die Optimierung wird für das neue Zeitfenster erneut durchgeführt. Der Ansatz stellt sicher, dass Entscheidungen iterativ getroffen werden, wobei aktualisierte Informationen im Laufe der Zeit berücksichtigt werden.

Die untenstehende Tabelle fasst die Eingabeparameter für die Optimierung zusammen.

*Tabelle 5. Eingabeparameter für die Optimierung*

| Parameter                         | Wert   | Einheit    | Beschreibung   |
|-----------------------------------|--------|------------|--|
| Batteriekapazität                 | 50     | kWh        | Die gesamte Kapazität der Batterie                             |
| Start- und Endbatterie (jährlich) | 25     | kWh        | Der Batteriestand zu Beginn und Ende der jährlichen Simulation |
| Ladeeffizienz                     | 0,98   | -          | Die Effizienz des Ladeprozesses                                |
| Gesamthorizont                    | 35.040 | Minuten    | Gesamter Optimierungshorizont (ein Jahr)                       |
| Rollierender Horizont             | 96     | Intervalle | Die Länge des rollierenden Horizonts (ein Tag)                 |
| Auflösung                         | 15     | Minuten    | Die zeitliche Auflösung des Optimierungsmodells                |

Es gibt vier Nebenbedingungen im Optimierungsmodell. Die erste definiert die maximal verfügbare Ladeleistung wie folgt:

$$P_{laden}(t) \leq P_{max}(t)$$

Wobei  $P_{laden}(t)$  die Ladeleistung zum Zeitpunkt  $t$  darstellt, und  $P_{max}(t)$  die maximal erlaubte Ladeleistung zum Zeitpunkt  $t$  darstellt. Diese Einschränkung stellt sicher, dass die Ladeleistung zu jedem gegebenen Zeitpunkt die maximal erlaubte Ladeleistung zu diesem Zeitpunkt nicht überschreitet.

Weitere Nebenbedingungen stellen sicher, dass die Batteriestände zu Beginn und am Ende des Optimierungshorizonts gleich sind, und dass die geladene Energie weder die Batteriekapazität noch die maximale Energie überschreitet, die in einem bestimmten Schritt geladen werden kann. Das bedeutet, dass der Batteriestand gleich dem Batteriestand des vorherigen Zeitpunkts plus der geladenen Energie im Zeitintervall  $T$  abzüglich des Energieverbrauchs für das Fahren ist.

$$E_{Batterie}(t) = E_{Batterie}(t - 1) + (\eta_{Laden} \cdot P_{laden}(t) \cdot \Delta t) - E_{Fahrenergie}(t)$$

Wobei  $E_{Batterie}(t)$  der Batteriestand zum Zeitpunkt  $t$  ist,  $E_{Batterie}(t - 1)$  der Batteriestand des vorherigen Zeitschritts ist,  $\eta_{Laden}$  der Ladewirkungsgrad ist,  $P_{laden}(t)$  die Ladeleistung zum Zeitpunkt  $t$  ist,  $\Delta t$  die Dauer des Zeitschritts ist, und  $E_{Fahrenergie}(t)$  die für die Fahrt verbrauchte Energie zum Zeitpunkt  $t$  ist.

$$E_{Batterie}(T) = E_{Batterie,Ende}$$

Wobei  $E_{Batterie}(T)$  der Batteriestand zum Ende des Optimierungszeitraums ist, und  $E_{Batterie,Ende}$  die vorgegebene Batteriekapazität zum Ende des Optimierungszeitraums ist.

Eine letzte Einschränkung sorgt dafür, dass das Fahrzeug genügend Energie in der Batterie gespeichert hat, um Fahrten am folgenden Tag durchzuführen. Diese Annahme wird getroffen, um eine Modell-Unlösbarkeit zu vermeiden, die auftreten kann, wenn ein Fahrzeug an einem bestimmten Tag nicht lädt, aber für Fahrten am nächsten Tag ein höherer Energiebedarf besteht als die verfügbare Energie in der Batterie. Diese Annahme wird als vernünftig betrachtet, da die meisten Elektrofahrzeug-Fahrer die voraussichtlichen Fahrten am nächsten Tag kennen und ihr Fahrzeug entsprechend aufladen würden.

$$E_{Batterie}(t) \geq E_{min,Ladebedarf}$$

Wobei  $E_{Batterie}(t)$  der Batteriestand zum Zeitpunkt  $t$  ist, und  $E_{min,Ladebedarf}$  der Ladebedarf der minimale Energiebedarf für zukünftige Fahrten ist, der vor der nächsten Fahrt geladen werden muss.

Diese Einschränkung stellt sicher, dass zu einem bestimmten Zeitpunkt  $t$  im Modell, wenn es der letzte Zeitschritt des aktuellen Zeitintervalls ist (aber nicht das Ende des gesamten Optimierungszeitraums), der Batteriestand mindestens den erforderlichen minimalen Energiebedarf für die Fahrten am nächsten Tag abdeckt. Das bedeutet, dass genügend Energie in der Batterie vorhanden sein muss, um die Anforderungen für die zukünftigen Fahrten zu erfüllen. Diese Einschränkung stellt sicher, dass die Batterie genug Energie enthält, um alle geplanten Fahrten nach dem aktuellen Zeitschritt zu ermöglichen. Wenn es sich um den letzten Zeitschritt des aktuellen Intervalls handelt und nicht das Ende des gesamten Optimierungszeitraums, wird überprüft, ob dieser Energiebedarf erfüllt ist. Andernfalls wird die Einschränkung übersprungen.

Schließlich werden die Lastprofile für die beiden Haushaltscluster mit Elektrofahrzeugen anhand des Haushaltsdiffusionsmodells hochskaliert. Die Anzahl der Haushalte für die spezifischen Cluster wurde gemäß dem folgenden Diffusionsmodell in die aggregierte Last einbezogen. Die Gesamtzahl der

Haushalte beträgt 41 Millionen. Für Cluster 2 wurde ein Anteil von 1,5 % und für Cluster 14 ein Anteil von 1 % kalkuliert.

### 3.4.3 Zusammenfassung

Das entwickelte preis-optimierte Mikromodell für Elektrofahrzeuge ermöglicht die Ermittlung des kostenminimalen Ladevorgangs von Elektrofahrzeugen unter Berücksichtigung dynamischer Strompreise. Im Rahmen der Projektlaufzeit wurde das bestehende `venco.py` Modell weiterentwickelt, um die Mobilität spezifischer Haushaltscluster besser abzubilden. Zusätzlich wurde eine neue Preisoptimierung entwickelt, die eine Berechnung des optimalen, preisminimierten Ladevorgangs ermöglicht. Es ist offen verfügbar unter:

[https://gitlab.com/dlr-ve/esy/vencopy/vencopy/-/tree/project/En4U?ref\\_type=heads](https://gitlab.com/dlr-ve/esy/vencopy/vencopy/-/tree/project/En4U?ref_type=heads)

## 3.5 Weiterentwicklung des Maschinellen Lernens bei der Lastaggregation

### 3.5.1 Einführung

Ausgangspunkt des Projekts sind die vielfältigen Unsicherheiten, z. B. Diffusion oder Preisentwicklungen bezüglich der Technologien Photovoltaik, Wärmepumpen und Elektromobilität. Wie die zukünftige Marktdurchdringung dieser drei Technologien und ihrer Interaktionen aussehen wird, ist völlig unklar. Für eine Bottom-up Simulation muss zunächst jede dieser Technologien auf Einzelhaushaltsebene modelliert werden. Danach kann über Diffusionsmodelle der jeweilige zukünftige Anteil abgeschätzt werden.

Allerdings ist es problematisch, viele Tausende Einzelbetriebsentscheidungen in ein nationales Energiesystem-Analysemodell einzubinden, wie es AMIRIS ist. Nichtsdestotrotz würde eine Aggregation nicht die vielfältigen Muster abbilden. Diese sind aber notwendig, um präzise Entscheidungssituationen modellieren zu können. Dies betrifft v.a. Unsicherheiten wie Investition und Betrieb von PVS, E-Pkw und Wärmepumpen – eine einfache Aggregation kann der Dynamik nicht gerecht werden.

Als Lösung werden diese Entscheidungen mittels neuronaler Netze so abstrahiert, dass die entstehende Gesamtnachfrage in AMIRIS effizient integriert werden kann. Dafür wird zunächst für bestimmte Typhaushalte und bestimmte Typtage das ökonomisch beste Modell berechnet. Für jede Technologie (PVS, Wärmepumpen, E-Pkw) werden somit viele tausende preisoptimale Betriebsstrategien kalkuliert. Dies dient den neuronalen Netzen als Trainingsdaten. Die neuronalen Netze sagen aus diesen Einzelstrategien den Gesamtverbrauch pro Technologie für Deutschland zu einer gegebenen Stunde voraus. Da das zeitlich aufwändige Training vor der Simulation stattfinden kann, müssen zum Simulationszeitpunkt nur die jeweils aktuellen Inputdaten, etwa der momentane Preis aus AMIRIS abgefragt werden, um die Vorhersage des fertig trainierten Modells über die Schnittstelle zu erhalten. Damit ist der Haushaltslevel zeiteffizient, dynamisch und sehr genau in das nationale Energiesystem-Analysemodell AMIRIS eingebunden.

Auf der technischen Seite musste zunächst die Software ausgewählt werden, mit der die Zeitreihenvorhersagen optimal durchgeführt werden konnten. Die Wahl fiel auf eine Selbstentwicklung auf Basis vorhandener, ausgereifter Pakete (Darts 3.8, siehe <https://pypi.org/project/darts/>). Die getestete Kernfunktionalität von Darts wurde um benötigte Funktionen, Wrapper usw. erweitert (siehe (Nitsch et al. 2024) und <https://zenodo.org/records/7792751>).

Der nächste Schritt bestand darin, aus der Vielzahl der verfügbaren Algorithmen, wie z. B. ARIMA, XGBoost, RNNModels, N-Beats, Temporal Fusion Transformer (TFT), oder Random Forests (siehe [https://unit8co.github.io/darts/generated\\_api/darts.models.forecasting.html](https://unit8co.github.io/darts/generated_api/darts.models.forecasting.html)), denjenigen mit der geringsten Fehlerquote für das gegebene energiesystemanalytische Problem und unsere Daten auszuwählen.

Parallel fand eine weitere Eigenentwicklung mit Keras und LSTM statt. Diese ursprünglich zu Vergleichszwecken entwickelte Modelle erwiesen sich letztendlich den Darts-Algorithmen als überlegen. Sie wurden für die Produktion ausgewählt.

Es wird ein Standard-Workflow gewählt. Zunächst werden die Input-Daten eingelesen und skaliert, damit beim Training Variablen mit vergleichsweise großen Werten nicht zu starken Einfluss bekommen.

### 3.5.2 Modellerweiterung

Unser Gesamtansatz, der im Projekt benutzt wurden, bietet ein umfassendes Software-Framework für das Training von LSTM-Modellen zur Vorhersage der aggregierten Netzinteraktion von Haushalten mit PV, E-Pkw und HP in Deutschland. Das Software-Framework integriert Diffusionsdaten, um die Repräsentation jedes Haushaltstyps in ganz Deutschland zu berücksichtigen und sicherzustellen, dass die resultierenden aggregierten Daten das Verhalten der Bevölkerung realistisch widerspiegeln.

Das Hauptziel ist die Vorhersage der aggregierten Netzinteraktion durch die Nutzung von Zeitreihendaten, die aus optimierten individuellen Haushaltsentscheidungen stammen. Die individuelle Netzinteraktion wird zum Beispiel bei der PV-Technologie von Faktoren wie PV-Kapazität, Batteriegröße, Nachfrageprofilen und anderen Parametern beeinflusst, die auf jeden Haushaltstyp zugeschnitten sind.

Der Prozess der Datenaufbereitung beginnt mit den Optimierungsergebnissen der einzelnen Haushalte für ein bestimmtes Jahr und den entsprechenden Wetterdaten. Diese Optimierungen ergeben Zeitreihen für jeden Haushaltstyp, jedes Jahr und jeden Wetterstandort. Mit Hilfe der Diffusionsdaten werden diese Zeitreihen gewichtet und aggregiert, um die gesamte Bevölkerung der deutschen Haushalte zu repräsentieren. Diese aggregierten Daten dienen als Grundlage für das Training der LSTM-Modelle.

Ein wesentliches Merkmal unseres Frameworks ist die Fähigkeit, verschiedene Lookup-Fenster für unterschiedliche Eingabevariablen zu verarbeiten. Dadurch wird sichergestellt, dass die einzigartigen sequentiellen Abhängigkeiten jeder Variable angemessen erfasst werden. Das Framework gibt der sequentiellen Struktur der Daten den Vorrang vor einer strikten zeitlichen Ausrichtung und erkennt an, dass die Reihenfolge und die Beziehungen zwischen den Datenpunkten für das Verständnis der Verhaltensmuster im Haushalt entscheidend sind.

Angesichts des aggregierten Trainingsdatensatzes für eine bestimmte Technologie werden die Daten skaliert und in Trainings-, Validierungs- und Testdatensätze aufgeteilt. Über die Trainings- und Validierungsdaten wird eine vierfache Kreuzvalidierung (Cross-Validation) durchgeführt, um sicherzustellen, dass das Modell über verschiedene Datensätze hinweg gut verallgemeinert. Das LSTM-Modell wird inkrementell auf mehreren der bereitgestellten Datensätze trainiert und das beste Modell wird anhand des Validierungsverlusts über alle Kreuzvalidierungen und Epochen hinweg ermittelt.

Das Framework gewährleistet einen nahtlosen Vorhersageprozess, indem es den Skalierer, das Format der Eingabevariablen und die zugehörigen Metadaten zusammen mit dem trainierten Modell speichert. Diese Komponenten werden als Teil des trainierten Modellobjekts gespeichert, was die Vorhersagen vereinfacht. Bei einem gespeicherten Modell und einer Zeitreihe (oder Sequenz) von Eingabevariablen ruft das Vorhersagesystem alle erforderlichen Informationen ab, wie z.B. den angewandten Skalierer für die inversen Transformationen und das erwartete Eingabeformat aus den Metadaten. Dadurch wird sichergestellt, dass Vorhersagen ohne manuelle Neukonfiguration durchgeführt werden können, was die Bereitstellung und Verwendung in realen Anwendungen vereinfacht. Damit bietet dieses Software-Framework eine skalierbare und reproduzierbare Lösung für die Analyse und Vorhersage von Netzinteraktionen für PVS, E-Pkw und Wärmepumpen.

Durch die Bewältigung der Herausforderungen bei der Aggregation verschiedener Haushaltstypen und der Verwaltung unterschiedlicher Abhängigkeiten von Eingangsvariablen schafft es eine solide Grundlage für zukünftige Studien zur Energieoptimierung und -prognose.

### 3.5.2.1 *Modelldetails*

Die folgende Abbildung zeigt unsere Standard LSTM Architektur:

```
model = Sequential()
model.add(InputLayer((X_train.shape[1], X_train.shape[2])))
model.add(LSTM(units=64, return_sequences=True))
model.add(LSTM(units=128, return_sequences=True))
model.add(LSTM(units=256, return_sequences=True))
model.add(LSTM(units=512, return_sequences=True))
model.add(LSTM(units=256, dropout=0.10))
model.add(Dense(units=64, activation='relu'))
model.add(Dense(units=1, activation='linear'))
```

Abbildung 5. Aufbau des LSTM-Modells

Das sequentielle LSTM-Modell besteht demnach aus fünf LSTM-Ebenen mit jeweils 64, 128, 256, 512 und 256 Neuronen. Die letzte Schicht wird mit einem Drop-out von 10% versehen, um den Lernprozess besser generalisieren zu lassen. Am Ende stehen zwei „Dense“-Ebenen mit 64 Einheiten und der Aktivierungsfunktion „relu“, und der linearen Ausgabeschicht mit einem Neuron.

Für möglichst benutzerfreundliche und fehlerfreie Konfigurationen wurden alle Trainingsparameter in YAML-Dateien abgelegt und gelesen. Als Optimum erwies sich ein Training von 200 Epochen für jedes Modell, geringere oder höhere Laufzeiten führten zu höheren Fehlern. Jedes Keras-Modell wird als Pickle gespeichert, inklusive der Metadaten. Dies erlaubt eine Trennung von Training und Testen, was wiederum den Vergleich von Modellböden über längere Zeiträume ermöglicht. Das Training findet auf 90 % der Daten statt, die restlichen 10 % werden für den Test verwendet. Während des Trainings wird eine vierfache Crossvalidierung für jedes Modell vorgenommen. Sowohl Training, Validierung als auch Tests finden auch skalierten Daten statt. Für die Ergebnisinterpretation werden sie zurück transformiert.

Die Modelle werden anhand verschiedener Fehlermaße miteinander verglichen. Verwendet werden die Standard-Fehlermaße MSE, RMSE und MAE. Zusätzlich werden die minimal und maximal vorausgesagten Werte ausgegeben. Das Modell mit dem geringsten MSE wird ausgewählt.

Die Wetterzeitreihen, die als Input dienen, sind entscheidend für die Qualität der Ergebnisse. Es wurde zunächst auf den Städten München, Hamburg, Stuttgart, Frankfurt, Köln, Berlin trainiert, bevor auf die für die Wetterregionen in Deutschland repräsentativeren Städte Kiel, Münster, München, und Würzburg gewechselt wurde. Schließlich wurde ein generelles Modell entwickelt, das Trainingsdaten aller vier Städte zusammenfasst. Die Ergebnisse dieser Modelle sind in Abschnitt 8.5 zusammengefasst.

Die folgenden Tabellen zeigen für die drei Modelle die jeweiligen Inputs, d. h. die Features an, mit denen die Modelle trainiert wurden. Da es sich um Zeitreihen handelt, wird jeweils ein Zeitraum in die Zukunft bzw. in die Vergangenheit mit betrachtet und geht in die Vorhersage mit ein.

### Elektromobilität:

*Tabelle 6. Input und Output-Variablen für das E-Pkw-Modell*

| Variablen-Name   | Vorausschau (Look-Ahead) oder Zurückschau in Stunden |
|--|--|
| price_EUR_per_kWh_15min                                | Forward: 96  |
| aggregated_available_charging_power_cluster_kW         | Forward: 96  |
| aggregated_elec_consumption_cluster_kWh                | Forward: 96  |
| ev_battery_level_cluster_kWh                           | Forward: 96  |
| aggregated_optimised_load_cluster_kW (Target variable) | Backward: 24   |

### Photovoltaik und Speicher:

*Tabelle 7. Input und Output-Variablen für das PVS-Modell*

| Variablen-Name        | Vorausschau (Look-Ahead) oder Zurückschau in Stunden |
|-----------------------|--|
| City                  | -  |
| energyGenerationPerMW | Forward: 24  |
| storedMWh             | Forward: 1   |



|   |              |
|---|--------------|
| prosumersLoadInMW                       | Forward: 24  |
| aggregatorSalesPriceInEURperMWH         | Forward: 24  |
| prosumersGridInteraction (Zielvariable) | Backward: 24 |

---

### Wärmepumpen:

*Tabelle 8. Input und Output-Variablen für das Wärmepumpen-Modell*

| <b>Variablen-Name</b>                 | <b>Vorausschau (Look-Ahead) oder Zurückschau in Stunden</b> |
|---------------------------------------|---|
| ambient_temperature                   | Forward: 48   |
| solar_radiation                       | Forward: 48   |
| price                                 | Forward: 48   |
| tapping_profile                       | Forward: 48   |
| aggregated_consumption (Zielvariable) | Backward: 48  |

---

### 3.5.3 Zusammenfassung und neue Erkenntnisse

Durch das Testen vielfältiger ML-Architekturen und verschiedener Datensätze mit unterschiedlichen zeitlichen Auflösungen und verschiedenen Trainingsparametern konnte ein ML-Modell gefunden werden, das den Gesamtverbrauch individueller Haushalte auf Basis weniger Variablen relativ präzise für jede der drei untersuchten Technologien voraussagen kann.

Diese trainierten Modelle werden über die oben beschriebene Schnittstelle mit AMIRIS angesteuert und liefern stündlich eine präzise, den Gegebenheiten dynamisch angepasste Vorhersage des Gesamtstromverbrauchs jedes der drei Sektoren.

## 4 Methodenentwicklung IIP: Diffusionsmodell (IIP)

### 4.1 Einführung in das Modell

Das Forschungsfeld der Diffusionsmodellierungen hat sich in den vergangenen Jahrzehnten dynamisch weiterentwickelt, sodass die Diffusionsforschung und die damit verbundene Modellierung insbesondere seit 1990 in verschiedenen Bereichen verwendet wird (Li und Sui 2011). In Folge des Bedeutungszuwachses sind in der Fachliteratur heute zahlreiche verschiedene Modellierungsansätze bekannt. Eine weit verbreitete Methode zur Erklärung der Diffusion von Technologien sind

Epidemische Modelle, welche auf der grundsätzlichen Idee basieren, dass die Adoption durch einen Informationsmangel seitens der Nicht-Adoptierenden beschränkt wird. Durch den Kontakt zwischen bereits etablierten Nutzern und den noch übrigen potentiellen Nutzern werden Informationen übertragen, was für die weitere Verbreitung der entsprechenden Technologie sorgt. Die Adoptionsrate lässt sich daher in einem Epidemischen Modell als eine Funktion des Produkts aus der Anzahl der Nicht-Adoptierenden und dem Anteil der Adoptierenden beschreiben. Daraus resultierende Modellierungsansätze, die sowohl externe als auch interne Faktoren berücksichtigen, sind Mixed-Influence Modelle (Bakher Naseri und Elliott 2013), wobei der populärste Ansatz das Bass-Diffusionsmodell darstellt (Bass 1969). Konkret basiert das Modell auf der Annahme, dass der Diffusionsprozess von Innovationen stets in einem sozialen System sowie über verschiedene Kommunikationskanäle stattfindet. Im Modell von Bass werden mit den Massenmedien und der Mundpropaganda insbesondere zwei Kommunikationskanäle für die Modellierung berücksichtigt. Beide Wege führen in Kombination dazu, dass sich potentielle Neukunden dafür entscheiden, eine Innovation zu übernehmen. Der erstgenannte Kanal wird im Rahmen der Diffusionsmodellierung als externer Einflussfaktor und der zweitgenannte als interner Einflussfaktor verstanden (Ismail 2013). Die Grundform des Modells beschreibt die Adoptionsrate  $S(t)$  unter Einbeziehung der bisherigen kumulativen Adoption  $N(t)$ , dem gesamten Adoptionspotential  $m$  sowie dem Innovations- und Imitationskoeffizienten ( $p$  und  $q$ ) zum Zeitpunkt  $t$ . Der Zusammenhang ist anhand der folgenden Funktion dargestellt:

$$S(t) = [p + mq N(t)] [m - N(t)] \quad \text{Eq. 10}$$

Anschließend werden die Parameter unter Berücksichtigung verschiedener Marktpotenzialszenerien anhand der Nonlinear Least Squares (NLS)-Methode geschätzt, was es erlaubt, den weiteren Diffusionsverlauf zu extrapolieren und entsprechende Prognosen zu erstellen.

## 4.2 Modellerweiterung

Das Bass Modell dient insbesondere dazu, Diffusionsprozesse auf aggregierter Ebene zu modellieren, wobei eine tiefgreifendere Analyse der Haushaltsentscheidungen in Bezug auf die untersuchten Technologien vernachlässigt wird. Um ein besseres Verständnis zu entwickeln, welche Haushaltstypen in den unterschiedlichen Diffusionszeitpunkten abgebildet werden und welche Faktoren die Adoptionsentscheidungen beeinflussen, wurde das Bass-Diffusionsmodell ergänzt um eine Modellierung repräsentativer deutscher Haushaltsgruppen sowie optimaler Investitionsentscheidungen für die entsprechenden Technologien im Rahmen des Projektes (PV, PVS, E-Pkw).

Zur Modellierung von Referenzhaushalten in Deutschland wurden zwei quantitative Befragungen ( $N_1 = 809$ ,  $N_2 = 1002$ ) durchgeführt, wobei die Stichproben jeweils hinsichtlich Alter, Geschlecht, Einkommen und Haushaltsgröße repräsentativ für die deutsche Bevölkerung waren. Neben soziodemografischen Daten wie Alter oder Bildung wurden haushaltsspezifische Merkmale wie Haushaltseinkommen und -größe abgefragt. Darüber hinaus wurden Merkmale des Wohngebäudes, ausgewählte Energiedaten sowie die installierten Technologien (PV, PVS, Wärmepumpen, E-Pkw) und deren Installationsabsicht erfasst. Zur Modellierung der repräsentativen Haushaltsgruppen wurde eine Latent Class Analysis (LCA) mit Maximum-Likelihood-Schätzung unter Berücksichtigung der genannten Variablen verwendet. Die Latent-Class-Analyse ist ein modellbasierter Clustering-Ansatz, der die einzelnen Datenpunkte probabilistisch verschiedenen latenten Klassen zuordnet. Angesichts des Anteils der Beobachtungen in jeder Gruppe schätzt die LCA die Modellparameter anhand der bedingten Wahrscheinlichkeit von Beobachtungen für jede Variable innerhalb einer Gruppe (Bauer

2022; Benassi et al. 2020; Hagenaars und McCutcheon 2009; Vermunt und Magidson 2009). Dieses wahrscheinlichkeitsbasierte Clustering bietet einen konzeptionellen Vorteil gegenüber den traditionelleren Clustering-Methoden, die eine deterministische Zuordnung verwenden, da die Klassifizierungsunsicherheit ein expliziter Teil des statistischen Modells ist (Bauer 2022; Magidson und Vermunt 2002). Außerdem kann die LCA als statistisch robustere Methode für das Clustering angesehen werden, da die Methodik modellbasiert ist und so statistische Aussagen zur Bestimmung der geeigneten Anzahl von Clustern für eine Population ermöglicht (Sinha et al. 2021). Eine Reihe von Studien hat gezeigt, dass LCA oft besser abschneidet als K-Means oder andere deterministische Clustering-Algorithmen, insbesondere wenn dichotome Variablen berücksichtigt werden und die Anzahl der Cluster unbekannt ist, siehe z. B. (Brusco et al. 2017; Magidson und Vermunt 2002; Schreiber und Pekarik 2014).

Anschließend wurde für jeden dieser Typhaushalte ein entsprechendes Lastprofil auf Basis der Haushalts- und Gebäudecharakteristika sowie der spezifischen Region (Nord- Mittel- Süddeutschland) simuliert.

Zur Erschließung der Haushaltstypen, die bisher keine PV, PVS, oder E-Pkw adoptiert hatten, wurde eine weitere Modellierung zur Optimierung entsprechender Investitionsentscheidungen durchgeführt. Dazu wurde ein bestehendes Modell zur techno-ökonomischen Analyse von PV und PVS (Fett et al. 2021) weiterentwickelt und auf die identifizierten Typ-Haushalte angepasst. Dabei wurde zur Bewertung der Wirtschaftlichkeit von PV und PVS ein Betrachtungszeitraum von 20 Jahren festgelegt, wobei die Kapitalwerte für jede Kombination von PV-Anlagengröße (0-10 kWp mit einer Schrittgröße von 0,5 kWp) und Batteriegröße (0-10 kWh mit einer Schrittgröße von 0,5 kWh) sowie für jeden Typhaushalt ermittelt werden. Für die Berechnung werden die Kapitalwerte einschließlich der Investition, der Ausgaben für Strom und der Einnahmen aus der PV-Einspeisevergütung berechnet und mit den Kapitalwerten ohne Investition verglichen. Dazu wird der Batteriebetrieb für jede Systemkonfiguration und jeden Typhaushalt simuliert. Weitere Inputs des Modells sind die Stromgroßhandelspreise, Projektionen der verschiedenen Komponenten des Endkundenstrompreises sowie PV- und Batterieinstallationskosten. Die Haushalte gehen von abnehmender PV-Einspeisevergütung und einem Strompreisanstieg von 2 % pro Jahr aus, beides bezogen auf ihr Installationsjahr. Schließlich wird für jeden Typhaushalt, sofern profitable Investitionen bestehen, die Systemkonfiguration mit dem höchsten Kapitalwert gewählt. Eine genaue Beschreibung der ursprünglichen Version des Modells ist (Fett et al. 2021) zu entnehmen. Für die Modellerweiterung in En4U wurden demgegenüber insbesondere die Annahmen zu den Komponenten des Endkundenstrompreises, der Einspeisevergütung sowie den Preisen von PV und PVS angepasst. Darüber hinaus wurde das bestehende Modell auf die im Projekt entwickelten Typhaushalte übertragen und spezifiziert.

Ebenso wurde eine ähnliche Methodik zur Beurteilung der Wirtschaftlichkeit der kombinierten Installation von PV und E-Pkw im Vergleich zur reinen PV-Installation entwickelt. Die Kapitalwertbetrachtung von PV und E-Pkw berücksichtigt hierbei die PV-Stromerzeugung und deren Eigenverbrauch, insbesondere auch durch die Nutzung der E-Pkw. Ein positiver Kapitalwert zeigt dabei eine rentable Investition an, während ein negativer Wert auf eine wirtschaftlich weniger attraktive Lösung hinweist. Das Modell setzt eine stündliche zeitliche Auflösung ein, um präzise Daten zu Energieverbrauch und -erzeugung unter Berücksichtigung des E-Pkw im Haushalt bestmöglich abzubilden. Ebenso wurden Fahrprofile unter Berücksichtigung der MiD-Daten sowie des Typhaushalte berücksichtigt.

### 4.3 Zusammenfassung und neue Erkenntnisse

Durch die Integration repräsentativer Typhaushalte sowie der Optimierung der Investitionsentscheidungen entsprechender Haushalte bietet das Modell eine detaillierte und repräsentative Analyse der Diffusion von PV, PVS und E-Pkw. Während das Bass-Modell den allgemeinen Adoptionsverlauf abbildet, ermöglicht die LCA die Differenzierung nach Haushaltstypen basierend auf sozioökonomischen und gebäudebezogenen Merkmalen. Dies liefert tiefere Einblicke in Adoptionsmuster verschiedener Bevölkerungsgruppen. Zusätzlich berücksichtigt die Kapitalwertanalyse für jede Haushaltsgruppe unterschiedliche Systemkonfigurationen der Investition von PV und PVS, optimiert durch realitätsnahe Last- und Fahrprofile. Die entsprechenden Bass-Diffusionsmodelle sind zugänglich unter: <https://gitlab.kit.edu/kit/iip/opensource/En4U>.

## 5 Methodenentwicklung IOR: stochastisches Optimierungsmodell (IOR)

### 5.1 Einführung in das Modell

Das hier beschriebene Optimierungsmodell baut auf unserer in Kaya et al. (Kaya et al. 2024) zur Veröffentlichung eingereichten Arbeit auf. Modelle für die Planung des Stromausbaus mit langen Planungshorizonten und hoher zeitlicher Auflösung werden immer wichtiger, um die zunehmend werdende Komplexität des Stromsystems adäquat abzubilden. Diese Modelle stellen sicher, dass die Bedürfnisse der Stromsysteme in der Ausbauplanung erfasst werden. Allerdings sind diese Modelle in der Regel sehr umfangreich und ihre Lösung kann schwierig sein. Insbesondere die diskreten Merkmale, die auftretenden Unsicherheiten und die hohe zeitliche Auflösung stellen einen hohen Rechenaufwand dar. Wir berücksichtigen als unsichere Parameter unter anderem die wetterabhängige Erzeugung und die Marktpreise, die in den Planungsprozess für den Netzausbau einbezogen werden müssen.

Das resultierende, und die Simulation integrierende, Modell nennen wir „*power generation expansion planning*“ oder kurz PGEP. Die genaue Modellkopplung der Simulation und Optimierung beschreiben wir in Kapitel 6. Das resultierende PGEP Modell enthält so viele Variablen und Nebenbedingungen, dass wir dieses nicht monolithisch mit einem gemischt-ganzzahligen Ansatz lösen können. Selbst die sehr weit entwickelten kommerziellen Löser, wie Gurobi, Cplex oder Xpress-MP können das Modell nicht ansatzweise lösen. Daher bedarf es problemabhängiger und strukturausnutzender Algorithmen. Für die neu entwickelten Algorithmen verweisen wir auf die Arbeit Kaya et al. (Kaya et al. 2024) und die Kurzzusammenfassung in Kapitel 5.2.

Die stochastische Natur des PGEP erhöht die Komplexität der Berechnungen. Infolgedessen werden fortgeschrittene und maßgeschneiderte Zerlegungsverfahren immer wichtiger, um die Rechenkomplexität mehrstufiger stochastischer Probleme mit stündlichen Zeitaufösungen und einem langen Planungshorizont zu bewältigen. Außerdem funktionieren agentenbasierte Simulationen besonders gut mit dezentralen Modellen. Sie haben daher ein wachsendes Potenzial, über die Kopplung der Modelle für langfristige Energiesystemprobleme eingesetzt zu werden.

Wir fassen das Planungs- des Ausbauproblem der Stromerzeugung als Simulations-Optimierungsproblem in unserem PGEP. Dabei ist unser Ziel die Minimierung der Gesamtkosten, einschließlich der Investitions- und Betriebskosten, mit einem langen Planungshorizont und einer kurzen zeitlichen Auflösung unter Unsicherheiten. Wir konzentrieren uns auf politische, wirtschaftliche und sozio-ökonomische Unsicherheiten. Insbesondere die Brennstoff- und CO<sub>2</sub>-Preise werden von

politischen und wirtschaftlichen Faktoren beeinflusst. Darüber hinaus wird die Nachfrage durch die Marktdiffusion neuer Technologien wie Photovoltaik-Speicher (PV), Elektrofahrzeuge (E-Pkw) und Wärmepumpen (HP) beeinflusst.

## 5.2 Modellerweiterung

Der Optimierungsteil – also ohne die Simulation – kann als mathematisches Modell wie folgt dargestellt werden (Kaya et al. 2024):

$$\begin{aligned} \min & \sum_{t=1}^T \left[ \sum_{i \in I^N} y_{it}^N F_{it}^N + \sum_{b \in B} y_{bt}^B F_{bt}^B K_b^B \right] + \sum_{t=1}^T \left[ \sum_{i \in I^N} u_{it}^N F_{it}^{NOM} + \sum_{k \in I^E} y_{kt}^E F_{kt}^{EOM} + \sum_{b \in B} u_{bt}^B F_{bt}^{BOM} K_b^B \right] \\ & + \sum_{t=1}^T \left[ \sum_{\omega \in \Omega} \pi_{\omega} \left( a_{t\omega} E_{t\omega}^P + \sum_{h \in \mathcal{H}} \left( \sum_{i \in I^N} C_{it\omega}^{FN} q_{iht\omega}^N + \sum_{i \in I^N} C_{it\omega}^{VN} q_{iht\omega}^N + \sum_{k \in I^E} C_{kt\omega}^{FE} q_{kht\omega}^E + \sum_{k \in I^E} C_{kt\omega}^{VE} q_{kht\omega}^E + C^{LS} d_{ht\omega}^p \right) \right) \right] \end{aligned} \quad \text{Eq. 11}$$

s. t.

$$\sum_{i \in I^N} q_{iht\omega}^N + \sum_{k \in I^E} q_{kht\omega}^E + \sum_{b \in B_r} p_{bht\omega} - \sum_{b \in B_r} k_{bht\omega} + d_{rht\omega}^p \geq Q_{rht} \quad \forall \omega \in \Omega, h \in \mathcal{H}, t \in T \quad \text{Eq 12}$$

$$\sum_{h \in \mathcal{H}} \sum_{k \in I^E} q_{kht\omega}^E E_{kt}^{RE} + \sum_{h \in \mathcal{H}} \sum_{i \in I^N} q_{iht\omega}^N E_{it}^{RN} - a_{t\omega} \leq 0 \quad \forall \omega \in \Omega, t \in T \quad \text{Eq 13}$$

$$y_{kt}^E C_{kth} P_k^{min} \leq q_{kht\omega}^E \leq y_{kt}^E C_{kth} \quad \forall \omega \in \Omega, i \in I^E, h \in \mathcal{H}, t \in T \quad \text{Eq 14}$$

$$u_{it}^N C_{ith} P_i^{min} \leq q_{iht\omega}^N \leq u_{it}^N C_{ith} \quad \forall \omega \in \Omega, i \in I^N, h \in \mathcal{H}, t \in T \quad \text{Eq 15}$$

$$E_{bht\omega} = E_{bh-1t\omega} + \eta_b^c k_{bht\omega} \frac{p_{bht\omega}}{\eta_b^d} \quad \forall \omega \in \Omega, b \in B, h \in \mathcal{H}, h \geq 2, t \in T \quad \text{Eq 16}$$

$$E_{b1t\omega} = E_{bHt-1\omega} + \eta_b^c k_{b1t\omega} \frac{p_{b1t\omega}}{\eta_b^d} \quad \forall \omega \in \Omega, b \in B, t \in T, t \geq 2 \quad \text{Eq 17}$$

$$y_{bt}^B P_b^{min} \leq p_{bht\omega} \leq y_{bt}^B P_b^{max} \quad \forall \omega \in \Omega, b \in B, h \in \mathcal{H}, t \in T \quad \text{Eq 18}$$

$$y_{bt}^B P_b^{min} \leq k_{bht\omega} \leq y_{bt}^B P_b^{max} \quad \forall \omega \in \Omega, b \in B, h \in \mathcal{H}, t \in T \quad \text{Eq 19}$$

$$y_{bt}^B W_b^{min} \leq E_{bht\omega} \leq y_{bt}^B W_b^{max} \quad \forall \omega \in \Omega, b \in B, h \in \mathcal{H}, t \in T \quad \text{Eq 20}$$

$$y_{kt-1}^E - L_k^{min} \leq y_{kt}^E \leq y_{kt-1}^E \quad \forall i \in I^E, t \in T \quad \text{Eq 21}$$

$$\sum_{t \in T} y_{bt}^B \leq 1 \quad \forall b \in B \quad \text{Eq 22}$$

$$u_{bt}^B = y_{bt}^B + u_{bt-1}^B \quad \forall b \in B, t \in T, t \geq 2 \quad \text{Eq 23}$$

$$u_{it}^N = y_{it}^N + u_{it-1}^N \quad \forall i \in I^N, t \in T \quad \text{Eq 24}$$

$$u_{it}^N \leq I_i^{max} \quad \forall i \in I^N, t \in T \quad \text{Eq 25}$$

$$\sum_{i \in I^N} y_{it}^N \leq U^{max} \quad \forall t \in T \quad \text{Eq 26}$$

$$y_{kt}^E, y_{it}^N, u_{it}^N \in Z^n \quad \forall i \in I^N, t \in T \quad \text{Eq 27}$$

$$y_{bt}^B \in \{0,1\} \quad \forall b \in B, t \in T \quad \text{Eq 28}$$

$$u_{bt}^B \in \{0,1\} \quad \forall b \in B, t \in T \quad \text{Eq 29}$$

Dieses Modell optimiert die nichtnegativen ganzzahligen Stromportfolioentscheidungen  $y_{kt}^E, y_{it}^N, u_{it}^N$ , die binären Energiespeicher-Investitionsentscheidungen  $y_{bt}^B, u_{bt}^B$  und die nichtnegativen kontinuierlichen Betriebsentscheidungen  $q_{kht\omega}^E, q_{iht\omega}^N, a_{t\omega}, d_{rht\omega}^p$ . Dabei gibt es  $I$  Kraftwerke,  $H$  Stunden,  $T$  Jahre,  $B$  Batterien und  $\Omega$  Szenarien.

In der Zielfunktion (Eq.10) werden die Gesamtkosten minimiert. Dazu gehören die Kosten für Investitionen, Betrieb und Wartung, Kraftstoff, Emissionen und Strafzahlungen. Die Ungleichungen (Eq.11) stellen die Gleichgewichtsbeschränkung dar. Die Randbedingungen (Eq.13) beschreiben das Emissionsniveau. Bedingungen (Eq.14) und (Eq.15) definieren Kapazitätsgrenzen für bestehende bzw. neue Generatoren. Die Nebenbedingungen (Eq.16) und (Eq.17) sorgen für ein Gleichgewicht zwischen Lade- und Entladetätigkeiten der Speichersysteme. Die Randbedingungen (Eq.18) - (Eq.20) schließlich legen die Betriebsgrenzen der Batteriespeichersysteme fest. Die Randbedingungen (Eq.21) - (Eq.24) werden zur Steuerung von Investitions- und Stilllegungsentscheidungen verwendet. Die Beschränkungen (Eq.25) und (Eq.26) legen den Investitionsentscheidungen Kapazitätsbeschränkungen auf. Die Restriktionen (Eq.27) - (Eq.29) definieren den Definitionsbereich der Variablen.

### 5.2.1 Lösungsalgorithmus

Wie bereits erwähnt führt die Kombination aus stündlicher zeitlicher Auflösung und der Modellierung von Unsicherheiten durch einen mehrstufigen stochastischen Prozess zu gigantischer Modellgröße. Die gute Nachricht ist allerdings, dass genau diese beiden Faktoren aber spezielle Strukturen in die Modelle integrieren. Abstrakt gesehen erzeugen diese Bedingungen eine blockdiagonale Struktur. Genau diese Struktur kann mit sogenannten Zerlegungsalgorithmen, basierend auf der Benders Dekomposition, ausgenutzt werden.

In der Tat sind Zerlegungsalgorithmen in der Literatur die wichtigsten und häufigsten Methoden zur Lösung von Leistungserweiterungsplanungsproblemen. Die Benders Dekomposition zerlegt das ursprüngliche Problem in ein Hauptproblem und ein Unterproblem. Dabei wird die Leistungserweiterungsplanung in der Regel als zweistufiges Optimierungsproblem interpretiert. In der ersten Stufe werden die Investitions- und Stilllegungsentscheidungen getroffen; in der zweiten Stufe dann die operativen Entscheidungen, basierend auf den getroffenen Investitions- und Stilllegungsentscheidungen der ersten Stufe. In unserem PGEP Modell ist das Problem der ersten Stufe ein gemischt-ganzzahlig lineares, während die zweite Stufe ein mehrstufiges stochastisches und lineares Optimierungsmodell ist. Das Unterproblem – assoziiert mit der zweiten Stufe – erbt Teile der Komplexität des Originalmodells. Insbesondere die zeitliche Auflösung und der mehrstufige stochastische Prozess machen das Unterproblem zu einem linearen Optimierungsproblem gigantischer Größe. Aber auch dieses Unterproblem behält die spezielle Struktur, bedingt durch den mehrstufigen Prozess. Daher können wir zum Lösen des Unterproblems auch wieder einen Zerlegungsalgorithmus anwenden – eine mehrstufige Benders Dekomposition.

Birge (Birge 1985) führte die so-genannte „Nested Benders Decomposition“ – eine mehrstufige Variante der Benders Dekomposition – ein. Diese wird auch als verschachtelte Benders Dekomposition genannt. Dieser Begriff erklärt sich dadurch, dass die (zwei-stufige) Benders Dekomposition iterativ auf verschachtelte, zweistufige Probleme angewendet wird. Daher eignet sich diese Methode prinzipiell

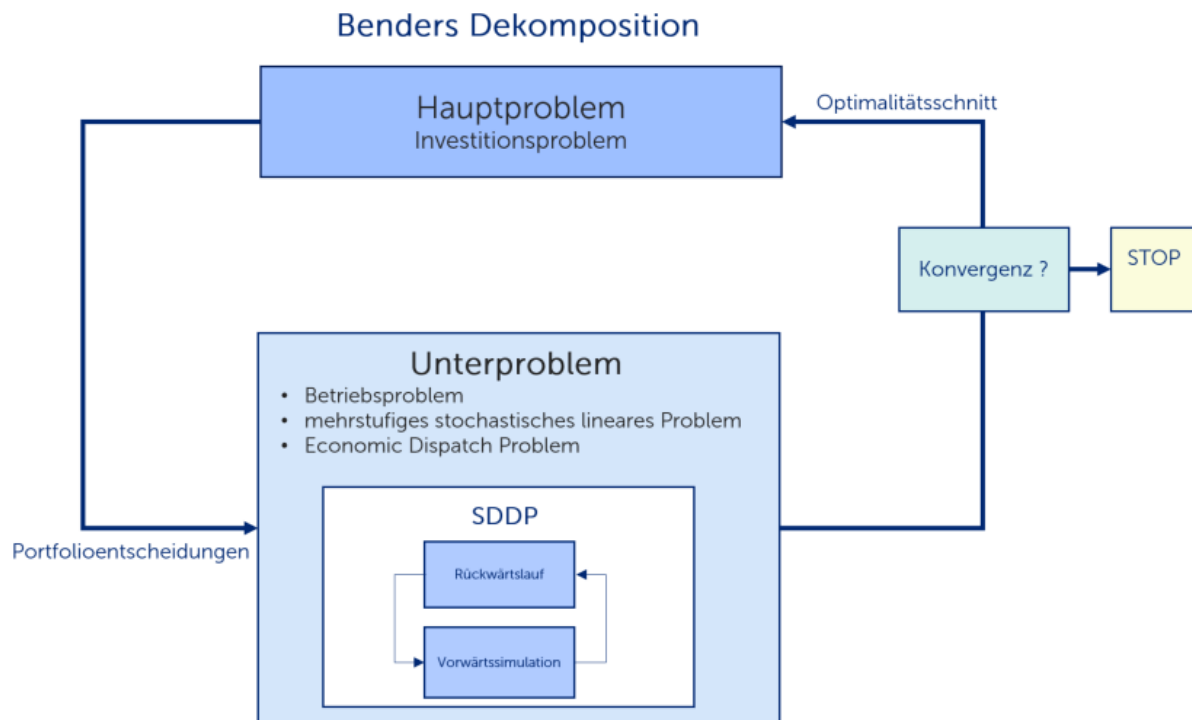
zum Lösen unseres Unterproblems, als mehrstufiges Problem. Allerdings leidet die verschachtelte Benders Dekomposition unter sogenanntem „Fluch der Dimensionalität“ (davon gibt es gleich mehrere). Ein solcher „Fluch“ entsteht dadurch, dass ein exponentieller Aufwand betrieben werden muss, um ein Problem zu lösen. Konkret werden alle Szenarien des mehrstufigen Prozesses (pro Iteration!) durchlaufen. Die Anzahl der Szenarien wächst allerdings exponentiell in der Anzahl der Stufen. Dies führt zu solch einem Fluch der Dimensionalität.

Pereira und Pinto (Pereira und Pinto 1991) schlugen eine auf Stichproben basierende Variante der verschachtelten Benders Dekomposition vor, den so-geannten Algorithmus der Stochastischen Dualen Dynamischen Programmierung (SDDP). Ziel war es, den „Fluch der Dimensionalität“ zu mildern. Dies wird dadurch erreicht, dass nicht alle Szenarien pro Iteration durchlaufen werden, sondern nur eine kleine Teilmenge – eine zufällig gezogene Stichprobe. Dies führt dazu, dass auch sehr große Optimierungsprobleme gelöst werden können. Der Nachteil ist, dass nur eine approximative obere Schranke (für Minimierungsprobleme) berechnet werden kann und dadurch das Verfahren keine optimale Lösung garantieren kann.

In Rebennack (Rebennack 2014) wird die Benders-Zerlegung zur Lösung des Planungsproblems der hydrothermalen Kraftwerkserweiterungsplanung verwendet. Die Teilprobleme sind mehrstufige stochastische lineare Optimierungsprobleme, die mit SDDP gelöst werden. Dieser entwickelte Algorithmus legt den Grundstein für die in diesem Projekt entwickelte Lösungsmethode des PGEP.

Den neu entwickelten Algorithmus schauen wir uns nun in einer abstrakten Form an und stellen die Verknüpfung zu unserem PGEP-Problem dar. Für die Details verweisen wir auf den eingereichten Artikel Kaya et al. (Kaya et al. 2024). Dazu betrachten wir noch einmal unser Anwendungsproblem. Wir planen den Ausbau der Stromerzeugung als Investitions- und Betriebsproblem. Dazu interpretieren wir die Planung des Ausbaus der Stromerzeugung als zweistufiges Optimierungsproblem. In der ersten Stufe werden Entscheidungen über das Stromportfolio getroffen – ein gemischt-ganzzahliges lineares Optimierungsproblem – während die betrieblichen Entscheidungen in der zweiten Stufe getroffen werden. Wichtig ist, dass das betriebliche Problem ein mehrstufiges stochastisches lineares Problem ist. Wir schlagen zur Lösung eine „doppelte Dekomposition“ vor, um diese spezielle Struktur unseres PGEP-Problems bestmöglich ausnutzen zu können.

Als Doppelzerlegungsalgorithmus kombinieren wir die Benders Dekomposition mit der SDDP. Das bedeutet, dass wir sowohl die zweistufige als auch die mehrstufige Struktur des PGEP-Problems gleichzeitig verwenden (wie in Abbildung 6 dargestellt). Dies ist bedeutsam, da wir unser PGEP-Problem aufgrund seiner mehrstufigen Struktur nicht nur mit zweistufiger Benders Dekomposition lösen können, und auch nicht nur mit SDDP, da wir diskrete Stromportfolioentscheidungen modellieren. Die Benders Dekomposition unterteilt unser Problem in ein Hauptproblem und ein Unterproblem. Das Hauptproblem stellt das Investitionsproblem dar, während das Unterproblem das operative Problem darstellt. In jeder Benders-Iteration werden die Testportfolioentscheidungen aus dem Hauptproblem bestimmt. Die operativen Entscheidungen werden anhand der Testportfolioentscheidungen durch SDDP optimiert. Die dadurch gewonnene Information wird mittels so-geannter Optimalitätsschnitte in das Hauptproblem integriert. Das aktualisierte Hauptproblem wird dann wieder gelöst um neue Portfolioentscheidungen zu generieren. Danach wird wieder das Unterproblem gelöst, bis eine Konvergenz erreicht wird und der Algorithmus stoppt.



16

Abbildung 6. Der Doppelzerlegungsalgorithmus

Um unseren Doppelzerlegungsalgorithmus zu erläutern, stellen wir das Standardproblem unseres PGEP-Problems wie folgt dar:

$$\min c_1^T x_1 + c_2^T x_2 \quad \text{Eq 30}$$

s. t.

$$A_1 x_1 = b_1 \quad \text{Eq 31}$$

$$A_2 x_1 + A_3 x_2 = b_2 \quad \text{Eq 32}$$

$$A_4 x_2 = b_3 \quad \text{Eq 33}$$

$$x_1, x_2 \geq 0 \quad \text{Eq 34}$$

$$x_1 \in N^{n_1} \times R^{n_2}, x_2 \in R^{n_2} \quad \text{Eq 35}$$

wobei  $x_1$  szenariounabhängige Stromportfolioentscheidungen sind;  $x_2$  sind szenarioabhängige Betriebsentscheidungen. Gleichungen (Eq.31) beziehen sich auf die Kapazitätsbeschränkungen. Gleichungen (Eq.32) koppeln die Kapazitäts- und Produktionsentscheidungen. Die Gleichungen (Eq.33) stellen betriebliche Beschränkungen sicher. Die Restriktionen (Eq.34) und (Eq.35) definieren den Entscheidungsraum der Variablen.

Das Teilproblem (Eq.36) - (Eq.38) wird iterativ für Testportfolioentscheidungen  $\hat{x}_1$  per Benders-Iterationen gelöst. Für jeden Benders-Durchlauf erhalten wir die dualen Werte  $\pi_k^2$ , um den Optimalitätsschnitt (Eq.42) zu berechnen. In unserem Fall ist das Teilproblem ein mehrstufiges



stochastisches lineares Problem, das monolithisch nicht gelöst werden kann; siehe oben. Daher verwenden wir SDDP, um das Teilproblem (approximativ) zu lösen. Das Teilproblem wiederum erzeugt einen (approximativen) Optimalitätsschnitt für das Hauptproblem. Dieser errechnet sich aus den Dualwerte des letzten Vorwärtsdurchlaufs von SDDP. Für die genaue Herleitung verweisen wir auf Kaya et al. (Kaya et al. 2024).

Für gegebene Testportfolioentscheidungen  $\hat{x}_1$ , ergibt sich folgendes Teilproblem:

$$z(\hat{x}_1) := \min c_2^\top x_2 \quad \text{Eq 36}$$

s. t.

$$A_3 x_2 = b_2 - A_2 \hat{x}_1 : \pi_k^2 \quad \text{Eq 37}$$

$$A_4 x_2 = b_3 : \pi_k^3 \quad \text{Eq 38}$$

wobei  $k \in K$  der Iterationsindex ist. Mit Hilfe der (starken) Dualitätstheorie berechnen sich die Schnittkoeffizienten der Optimalitätsschnitte des Hauptproblems pro Iteration  $k$  wie folgt:

$$\lambda_k^{var} = -(\pi_k^2)^\top A_2 \quad \text{Eq 39}$$

$$\lambda_k^{cons} = z(\hat{x}_1) - (\lambda_k^{var})^\top \hat{x}_1 \quad \text{Eq 30}$$

Die Evaluation des Teilproblems für die Entscheidungen des Teststromportfolios  $\hat{x}_1$  kann nun zur Bestimmung von (approximativen) Optimalitätsschnitten für das Hauptproblem verwendet werden. Hierzu sei  $\eta$  eine unbeschränkte kontinuierliche Entscheidungsvariable der Dimension 1. Wir erhalten das (relaxierte) Hauptproblem:

$$\min c_1^\top x_1 + \eta \quad \text{Eq 41}$$

s. t.

$$\eta \geq \lambda_k^{cons} + (\lambda_k^{var})^\top x_1 \quad \forall k \in K \quad \text{Eq 42}$$

$$A_1 x_1 = b_1 \quad \text{Eq 43}$$

$$x_1 \in N^{n_1} \times R^{n_2} \quad \text{Eq 44}$$

Dieses gemischt-ganzzahlige Optimierungsproblem in den Entscheidungsvariablen  $x_1$  ist eine Relaxierung des Hauptproblems, da nicht alle (endlich vielen) Optimalitätsschnitte enthalten sind, sondern nur diejenigen Schnitte, welche in den ersten  $K$  Iterationen der Benders Dekomposition berechnet worden sind. Den Algorithmus terminieren wir nach einer festen Anzahl an Iterationen (bzw. wenn sich die Portfolioentscheidungen nicht mehr ändern).

### 5.2.2 Integration von AMIRIS in das PGEP-Problem

In unserem PGEP-Problem integrieren wir das Optimierungsmodell mit einer agentenbasierten Strommarktsimulation (AMIRIS), die die Bewertung von Stromportfolioentscheidungen sowohl bei zentralisierten als auch bei marktbasierenden Systemen ermöglicht. Unser Ansatz beinhaltet sowohl „recourse“ als auch „wait-and-see“ Strategien, um Entscheidungen unter Unsicherheit effektiv zu

modellieren. Zusätzlich verwenden wir Marktdurchdringungs- und Diffusionsanalysen, um die prognostizierte Nachfrage zu bestimmen.

Abbildung 7 fasst unser Modell zusammen. Insbesondere erklärt sich hierdurch, dass wir AMIRIS mittels Optimalitätsschnitte in das Optimierungsmodell integrieren. Das Hauptproblem beinhaltet also nun zwei Arten von Optimalitätsschnitten: von dem Unterproblem, gelöst durch SDDP, und von AMIRIS. Eine solche Modellkopplung gibt es bisher in der Literatur nicht.

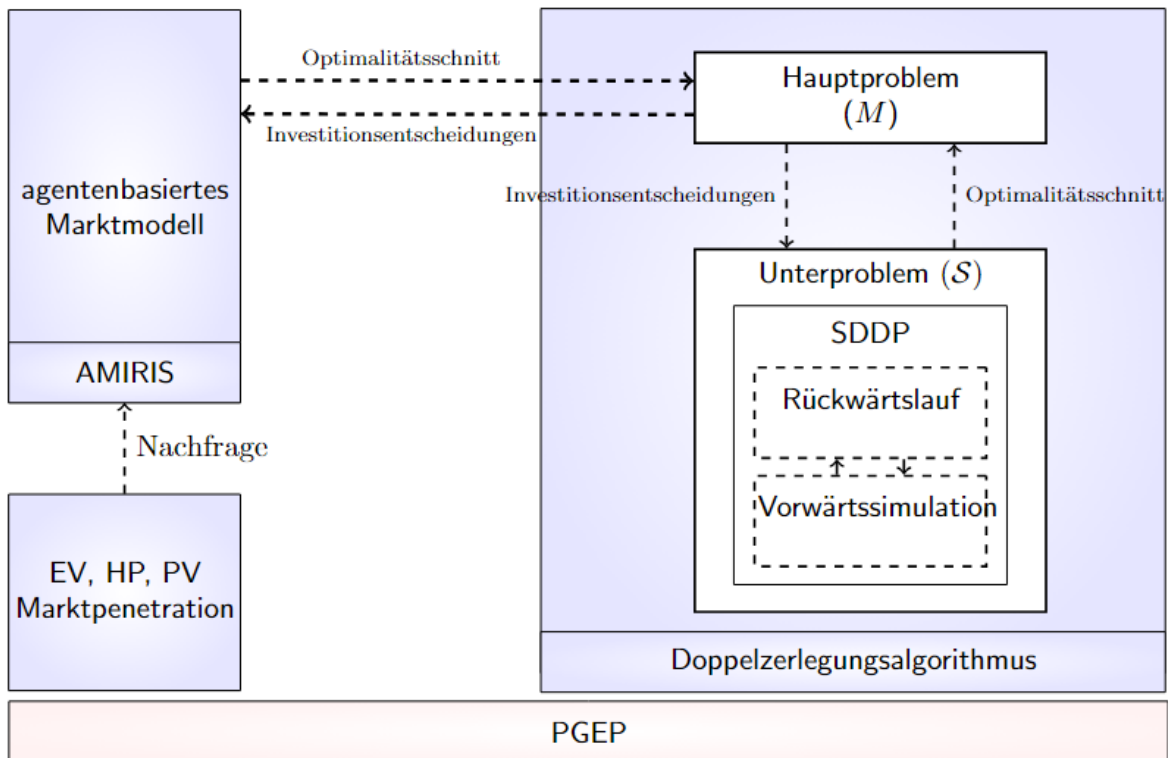


Abbildung 7. Das PGEP-Problem als Simulation-Optimierungsmodell und dem integrierten Doppelzerlegungsalgorithmus

Eine solche Modellkopplung hat gleich mehrere Herausforderungen:

- (1) Die Extraktion von den benötigten Optimalitätsschnitten in AMIRIS, da AMIRIS ein Simulationsmodell ist und kein lineares Optimierungsmodell. Dies beschreiben wir in Kapitel 6.3.
- (2) Da AMIRIS und das Optimierungsmodell zwei unterschiedliche Programme sind, müssen diese miteinander gekoppelt werden, damit die benötigten Daten transferiert werden können. Dies erfordert detaillierte Protokolle und die Synchronisation der Eingabedaten. Dies beschreiben wir in Kapitel 6.2.
- (3) Da das PGEP-Problem nun gleich zwei Optimalitätsschnitte enthält, müssen diese miteinander in Beziehung gesetzt werden. Hierfür haben wir drei Kopplungsstrategien entwickelt. Diese beschreiben wir nachfolgend.

### 5.2.3 Kopplungsstrategien: Integration von AMIRIS in das Optimierungsmodell

Es werden drei verschiedene Strategien entwickelt und verglichen, um das Optimierungsmodell mit AMIRIS zu kombinieren. Diese Entwicklung von Kopplungsstrategien ist ein neuer Beitrag zur Literatur. Jede Strategie wird im Folgenden einzeln vorgestellt:

**Strategie 1:** Diese Strategie besteht darin, AMIRIS als einziges Unterproblem mit dem Hauptproblem zu verbinden. Da AMIRIS den Betrieb des Strommarktes simuliert, berücksichtigen wir bei der Bestimmung der Portfolioentscheidungen nur den Betrieb des Strommarktes. Das heißt, die Stromportfolioentscheidungen werden ausschließlich mit Hilfe der aus AMIRIS extrahierten affinen Optimalitätsschnitte getroffen (Abbildung 8).

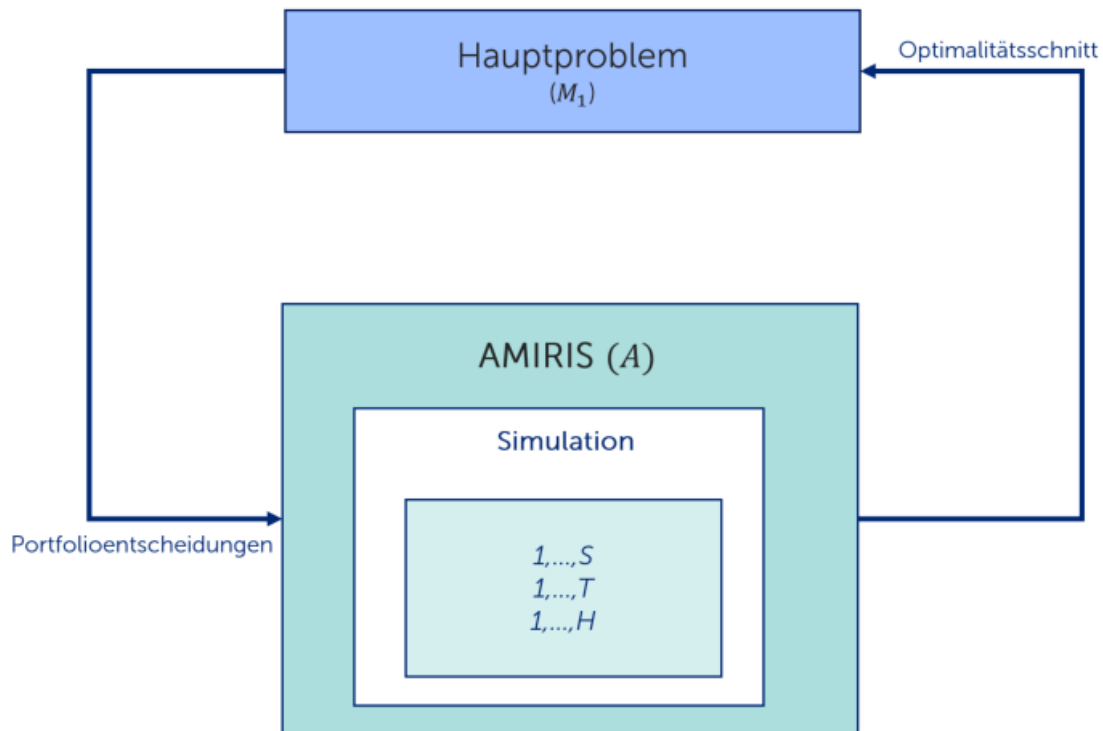


Abbildung 8. Kopplungsstrategie 1 zwischen AMIRIS und SOM

**Strategie 2:** Bei der zweiten Strategie werden sowohl AMIRIS und SDDP als Unterprobleme behandelt. Diese Unterprobleme werden sequentiell wie folgt gelöst. Erst wird das Optimierungsproblem mittels des Doppelzerlegungsalgorithmus gelöst. Danach wird die berechnete Portfolioentscheidung an AMIRIS übergeben. AMIRIS erzeugt dann Markt-Outputs und berechnet Optimalitätsschnitte für die Integration in da Optimierungsmodells (Abbildung 9). Alle Optimalitätsschnitte werden während des Prozesses gespeichert. Danach iteriert der Prozess bis eine Konvergenz erreicht ist.

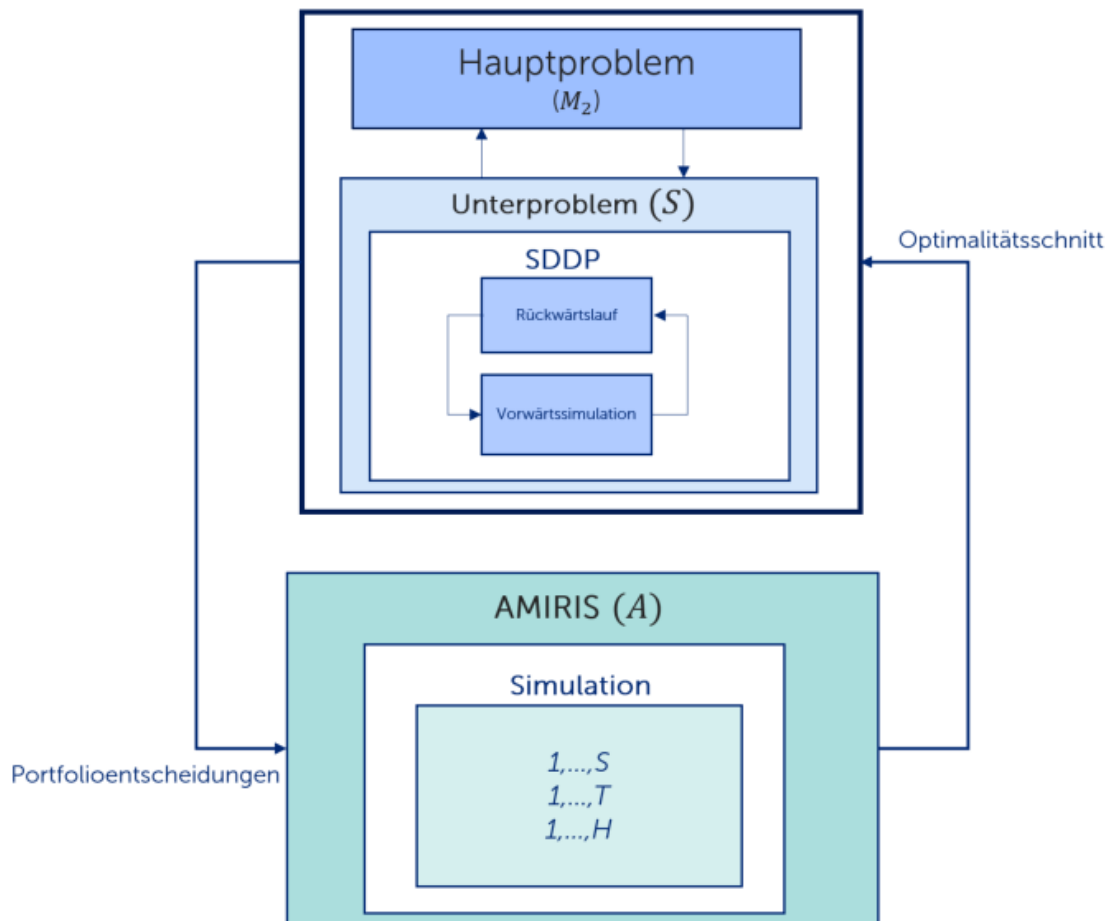


Abbildung 9. Kopplungsstrategie 2 zwischen AMIRIS und SOM

**Strategie 3:** Die letzte Strategie verbindet das Hauptproblem des PGEP-Modells sowohl mit SDDP als auch mit AMIRIS. Im Gegensatz zu Strategie 2 werden diese beiden Unterprobleme parallel berücksichtigt. Bei jeder Iteration laufen SDDP und AMIRIS gleichzeitig, um Optimalitätsschnitte für das Hauptproblem zu erzeugen. In der folgenden Iteration wird das Hauptproblem dann mit allen erzeugten Optimalitätsschnitten gelöst. Ferner werden die beiden unterschiedlichen Optimalitätsschnitte mit Hilfe der multikriteriellen Optimierung zusammengefügt, um Entscheidungen für das Stromportfolio zu treffen (Abbildung 10).

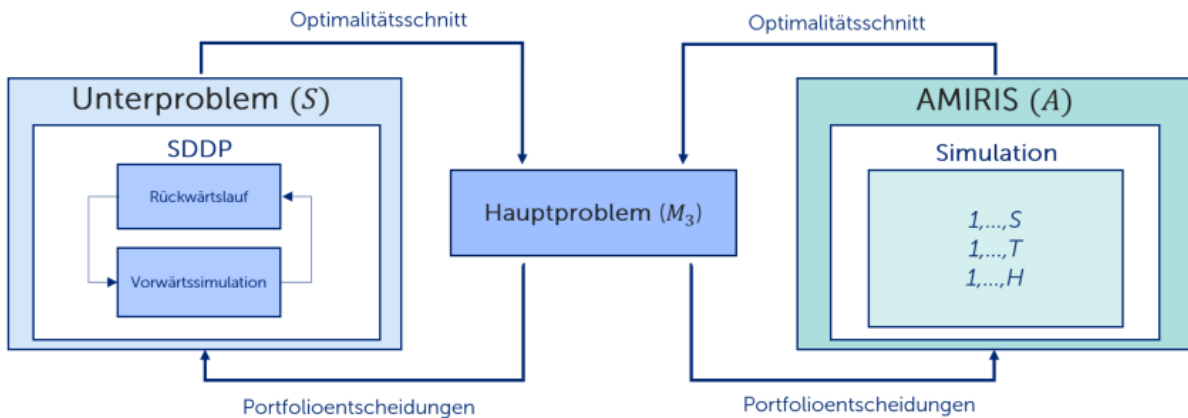


Abbildung 10. Kopplungsstrategie 3 zwischen AMIRIS und SOM

Für die mathematische Beschreibungen der drei Kopplungsstrategien und deren detaillierter Diskussion verweisen wir auf das Paper Kaya et al. (Kaya et al. 2024).

### 5.3 Zusammenfassung und neue Erkenntnisse

1. Wir behandeln das PGEP-Problem unter Unsicherheit als ein kombiniertes Simulations- und Optimierungsproblem. Dies ermöglicht die Bewertung von Stromportfolio-Entscheidungen sowohl bei zentralisierten als auch bei marktbasieren Systemen. Wir betrachten einen langen Planungshorizont und eine stündliche Zeitauflösung. Unsicherheiten werden in dem Optimierungsmodell ebenfalls berücksichtigt.
2. Wir stellen einen Doppelzerlegungsalgorithmus vor, der die Benders Dekomposition mit SDDP kombiniert. Dies stellt eine effektive Methode dar, um unser PGEP-Problem approximativ zu lösen. Neben den Portfolioentscheidungen erhalten wir auch eine valide untere Schranke and die optimale Lösung des PGEP-Problems.
3. Wir koppeln das Optimierungsmodell mit der agentenbasierten Simulation AMIRIS. Insbesondere untersuchen wir drei Kopplungsstrategien, die affine Optimalitätsschnitte verwenden, um die Ergebnisse der agentenbasierten Simulation in das Optimierungsmodell einzubeziehen.

## 6 Methodenentwicklung DLR und IOR: Kopplung PGEP und AMIRIS (DLR & IOR)

### 6.1 Motivation

Entscheidend für die Modellkopplung, die zentral für das Projektziel, das Verständnis des Einflusses einer unsicheren Umwelt auf Haushaltsentscheidungen in Kombination mit Unsicherheit über die Entwicklung des Kraftwerkparks war, ist deren technische Umsetzung, die ohne menschliches Eingreifen stattfinden muss. Zwischen den beiden Modellen AMIRIS und SOM müssen jedes Simulationsjahr mehrere Dateien mit Daten als Input für das jeweilig andere Modell ausgetauscht werden.

## 6.2 Beschreibung der Kopplungssoftware RCE

Eingesetzt wird die Software RCE (<https://rcenvironment.de/>). Sie ist in der Lage, AMIRIS und das SOM so zu koppeln, dass mehrere Jahre mit jährlichen Datenaustausch zwischen den Modellen vollautomatisiert simuliert werden können.

Aufgrund von Berechtigungs- und Sicherheitsproblemen innerhalb des DLR musste RCE in diesem Projekt auf einem externen Server (<https://www.hetzner.com/>) installiert werden.

Die recht komplexe Inbetriebnahme geschah mit Hilfe eines der Entwickler von RCE, Alexander Weinert. Die allgemeine Dokumentation zu RCE (Benutzer, Entwickler, Administrator) ist unter <https://rcenvironment.de/pages/documentation/documentation.html> zu finden.

Die folgende Beschreibung fasst kurz die einzelnen Schritte für die Reproduzierbarkeit zusammen:

### **Installation:**

1. Download der Software mit SCP und Installation
2. Anlegen der Benutzer und Hinzufügen zu existierenden Linux-Gruppen
3. Erstellen der RCE-Benutzer
4. Kopieren der RCE-Vorlagen
5. Erstellen der RCE-Profile in entsprechende Verzeichnisse
6. Setzen der korrekten Berechtigungen
7. Bei jeder Änderung: Neustart des Dämons und des Dienstes
8. Administration der Dienste, z. B. Statusabfrage, Stop, Start
9. Neuentwicklung und Änderungen: Der RCE-Server muss „headless“ neu gestartet werden
10. Vorhandene Komponenten werden über den Befehl „rce components“ gesucht

### **Sicherstellung der Netzwerkfähigkeit:**

1. Uplink erstellen über ssh und RCE client auf lokalem PC mit Firewall-Freischaltung
2. Benutzer anlegen in der Konsole des RCE-Clients
3. Manuell: User-Hashes in Konfiguration eintragen, Benutzer müssen in „accounts“ gespeichert werden
4. In der Datei configuration.json wird nur die jeweilige Rolle gespeichert, z. B. "uplink"
5. Einrichten einer Port-Weiterleitung auf Grund der DLR-Firewall

### **Entwicklung der Komponenten:**

1. Einzelne Workflows, also die gekoppelten Simulationsschritte, können den anderen Projektteilnehmern durch Veröffentlichung (Befehl „publish [...]“ zur Verfügung gestellt werden.
2. Die entwickelten Komponenten für den Workflow liegen unter dem Hauptbenutzer amiris. Danach werden sie für das Projekt öffentlich gemacht.
3. Der Hauptbenutzer, unter dem der RCE-Server läuft benötigt Adminrechte.
4. Die Fehlerbehebung erfolgt über die Logs „debug.log“ und der Suche nach dem Stichwort /ERROR in weiteren Dateien.

### 6.3 Vorgehen der Modellkopplung

In einem ersten Schritt muss die Konfigurationsdatei (*scenario.yaml*) von AMIRIS mit den Informationen des SOM-Modells bestückt werden. Dies geschieht durch ein selbstgeschriebenes Python-Skript (*add\_CE\_plants.py*), welches die konventionellen Kraftwerke, also den aktuellen Kraftwerkspark aus dem SOM, als Agenten in das Szenario hineinschreibt. Dies umfasst auch alle Parameter jedes einzelnen Kraftwerks, also z. B. die Effizienz oder die Leistung.

In einem zweiten Schritt müssen analog die Kraftwerke der erneuerbaren Energien ebenfalls in dieselbe Konfigurationsdatei geschrieben werden. Dies geschieht durch ein weiteres selbst entwickeltes Python-Skript (*add\_RE\_agents.py*). Parameter sind hier u.a. die zu Grunde liegenden Wetterzeitreihen, die Vergütungsinstrumente, Effizienzen, und Leistung.

In einem dritten Schritt wird mit dieser Konfigurationsdatei ein AMIRIS-Lauf (*run\_amiris.py*) gestartet. Die restlichen Parameter werden aus den Szenario-Daten von ARIADNE ebenfalls durch diverse Python-Skripte eingetragen, die die Daten extrahieren und auf Fehler prüfen. Für die Fehlererkennung ist ein Logging-System integriert. Die Ausgabe wird auf zwei Agenten begrenzt, nämlich *DemandTrader* und *EnergyExchangeMulti*. Diese enthalten alle Informationen, die im nächsten Schritt an das SOM weitergegeben werden.

In einem vierten Schritt werden die Ergebnisse aus AMIRIS ausgelesen. Ein weiteres Python-Skript (*extract\_data.py*) extrahiert wiederum aus den Ergebnisdateien die entscheidenden Daten, die an das SOM transferiert werden. Es handelt sich um drei CSV-Dateien (*demand.csv*, *systemcost.csv*, und *clearingprice.csv*). Sie speichern den Gesamtverbrauch für Deutschland, die Systemkosten und den Elektrizitätspreis pro Stunde. Alle diese Skripte sind öffentlich verfügbar im Repo (<https://gitlab.dlr.de/amiris/projects/iovrmr>).

In einem fünften Schritt nimmt das stochastische Optimierungsmodell diese Daten entgegen, und berechnet damit das optimierte Energiesystem für die nächsten 10 Jahre. Dieser optimierte Kraftwerkspark fließt wiederum, wie in Schritt eins, in AMIRIS ein. Dafür ist eine Anpassung des Markt-Clearing-Vorgehens in AMIRIS nötig.

Für den Benders Optimalitätsschnitt werden duale Werte des Markt-Clearing Problems benötigt. Hierbei sind die dualen Werte  $\mu$  der Kapazitätsbeschränkung aus AMIRIS von besonderer Bedeutung. Wir verzichten hier auf eine formale Herleitung der Dualwerte und des Optimalitätsschnitts und verweisen stattdessen auf den Artikel in Kaya et al. (Kaya et al. 2024). Wir beschränken uns auf eine inhaltliche Begründung.

Der duale Wert  $\mu$  stellt die marginale Verringerung der Gesamtsystemkosten dar, die durch die Erhöhung der Generatorleistung um eine Einheit erreicht wird. Daher kann die Differenz zwischen dem Markträumungspreis  $\lambda$  und den Grenzkosten  $G$  jedes genutzten Generators als die dualen Werte  $\mu$  in Bezug auf die Kapazitätsbeschränkungen der Generatoren interpretiert werden. Dies kann wie folgt formalisiert werden:

$$\mu_{ihtsr} = \begin{cases} 0, & \text{falls } y_{ihts}^* < \hat{x}_{it} \\ \lambda_{hts} - G_{ihts}, & \text{sonst} \end{cases} \quad \forall i \in I, \forall h \in H, \forall t \in T, \forall s \in S,$$

wobei  $y$  die Produktionsmenge und  $\hat{x}$  die Stromportfolioentscheidung (aus dem Hauptproblem) ist. Dabei nehmen wir an, dass es  $I$  Investitionsprojekte,  $H$  Stunden,  $T$  Jahre und  $S$  Szenarien gibt. Folglich

werden Stromportfolioentscheidungen, Systemkosten, Grenzkosten, Markt-Clearing-Preise und Nachfragedaten verwendet, um das SOM-Modell mit AMIRIS zu koppeln.

Für die Nachvollziehbarkeit sind hier einige der wichtigeren Skripte genannt: *split\_capacities\_by\_plant.py*, *split\_yield\_by\_plant.py*, *create\_ARIADNE\_demand\_TS\_from\_AMIRIS.py*, *fill\_ARIADNE\_demand\_years.py*.

Abbildung 11 zeigt diesen Workflow:

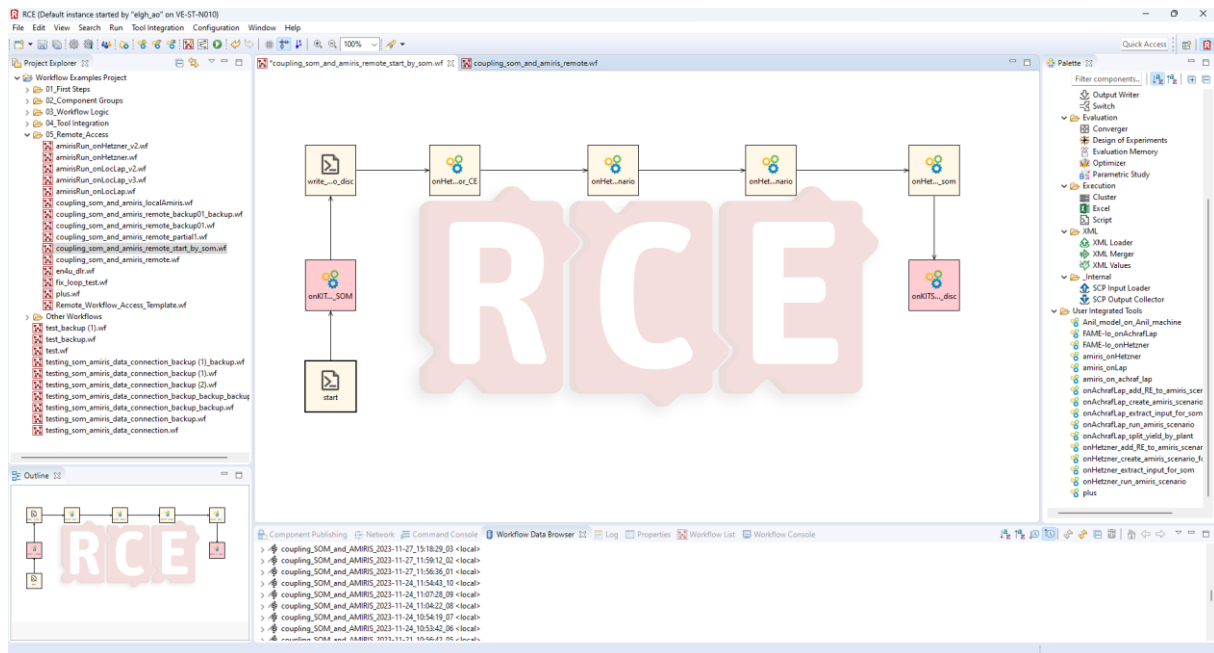


Abbildung 11. RCE-basierter Workflow der gekoppelten Modelle

Jeder Kasten stellt dabei eine selbst entwickelte Komponente dar. Die Komponenten, teils Modelle, teils Skripte, die Daten weitergeben, sind in einem Workflow miteinander verbunden, der auf verschiedenen Servern (Nürnberg, Karlsruhe) liegt.

Dieses voll automatisierte Vorgehen in einem RCE-Workflow erlaubt das verteilte Rechnen von Modellen, die von Minuten bis Tagen benötigen, ohne dass menschliches Eingreifen für den Start eines neuen Modells erforderlich ist. Die AMIRIS-Komponenten liegen auf dem externen Server, auf dem auch der RCE-Server liegt, die aufwändigeren Rechnungen für das Optimierungsmodell finden auf einem KIT-Cluster in Karlsruhe statt.

## 6.4 Zusammenfassung und neue Erkenntnisse

Der voll automatisierte Workflow ganz verschiedener Modelle, die in einer Schleife beliebig viele Iterationen simulieren können, erlaubt es, ganz neue Erkenntnisse zu gewinnen. AMIRIS ist nicht in der Lage, zukünftige Investitionen in den Kraftwerkspark zu berechnen, und das Optimierungsmodell ist nicht in der Lage, die einzelnen betriebswirtschaftlichen Entscheidungen der Akteure abzubilden. In einer engen Kopplung jedoch sind sie dazu fähig, da jedes Modell die eigenen Stärken ausspielen kann, und die Schwächen durch das jeweilige andere Modell übernommen werden.

Allerdings hat dieses Projekt gezeigt, dass die wissenschaftliche und technische Kopplung extrem komplex ist, und sehr viel Zeit benötigt. So war praktisch eine komplette Neuparametrisierung von



AMIRIS nötig, die mit entsprechenden Skripten hergestellt wurde, der Abgleich der Szenarien-Daten war ebenfalls zeitaufwendig, und die technische Umsetzung des SOM, sowie der Kopplung selbst erforderte einen immensen Zeitaufwand.

## 7 Datengrundlage

### 7.1 Vorbereitende Analyse politischer Unsicherheiten (IIP)

In diesem Abschnitt wird die Entwicklung der Szenarien beschrieben, die zur Analyse von Diffusion und Investitionsentscheidungen im Bereich PVS, E-Pkw und Wärmepumpen herangezogen wurden. Zur Ableitung konsistenter und fundierter Szenarien wurden zunächst Expertenworkshops durchgeführt, um die wichtigsten politischen Einflussfaktoren auf die Verbreitung dieser Technologien systematisch zu erfassen und zu bewerten.

Auf Basis vorangehender Befragungen von Experten wurden alternative politische Maßnahmenpakete zusammengetragen, die mögliche Entwicklungspfade der Energiepolitik in Deutschland abbilden. Diese Szenarien umfassten verschiedene politische Optionen wie etwa alternative Erhebungsformen der EEG-Umlage, verstärkte Förderregime für Elektrofahrzeuge sowie unterschiedliche Höhen der CO<sub>2</sub>-Bepreisung. Zur Analyse verschiedener Maßnahmenpakete wurden sowohl fördernde als auch hemmende Effekte unterschiedlicher politischer Maßnahmen auf die Diffusion der Technologien identifiziert sowie mögliche Zielkonflikte und Synergien evaluiert. Hierzu wurden Expertenworkshops abgehalten, deren Ergebnisse anschließend durch eine Cross-Impact-Balance (CIB)-Analyse (Kosow et al. 2022; Weimer-Jehle 2006) bewertet wurden. Hierbei wurden die Experteneinschätzungen zu den Wechselwirkungen zwischen den Maßnahmen quantifiziert und entsprechende Synergien evaluiert. Die Analyse ergab unter anderem, dass das Status-quo-Maßnahmenpaket sehr gut in der Verwirklichung der drei energiepolitischen Ziele eingeschätzt wird. Dies könnte darauf hindeuten, dass das derzeitige Maßnahmenpaket gut für die drei Gesamtziele geeignet ist, jedoch werden die Synergien – laut der CIB-Analyse – im Hinblick auf die Verbreitung von Technologien nicht maximal mobilisiert. Eine Maßnahme, die jedoch die Konsistenz des aktuellen Maßnahmenpakets minderte, war die Förderung von Batteriespeichern, welche inzwischen jedoch nicht mehr in Kraft ist. Ebenso ergab die Analyse, dass die Zusammensetzung der Endkundenstrompreise sowie die CO<sub>2</sub>-Bepreisung Auswirkungen auf die Konsistenz und Effektivität politischer Maßnahmenpakete haben. Insofern erschien es sinnvoll, auf Szenarien zurückzugreifen, die diese Aspekte betrachten.

Auf Grundlage der Expertenworkshops und dessen Analyse wurden relevante politische Einflussfaktoren identifiziert, die in der weiteren Szenarioentwicklung berücksichtigt würden. Die Analyse zeigte die Notwendigkeit, ein Szenario zu wählen, das die komplexen politischen Wechselwirkungen adäquat abbildet und auf einer umfassenden Datenbasis beruht. Eine weitergehende Analyse von Szenarien auf Basis der Erkenntnisse der Expertenworkshops identifizierte den ARIADNE-Report als am besten geeignete Datenbasis (siehe auch den nächsten Abschnitt 7.2).

### 7.2 Szenarien

#### 7.2.1 Grundlagen der Szenarioentwicklung

Die verwendeten Modelle AMIRIS und SOM benötigen exogene Rahmenannahmen zur Entwicklung des Energiesystems in Deutschland. Zu diesem Zweck wurden relevante Studien für das Energiesystem Deutschlands recherchiert und in Bezug auf die Nutzbarkeit für die Szenarioentwicklung in En4U ausgewertet. Dabei wurden die folgenden drei groß angelegten Studien und der Expertenworkshop (siehe Abschnitt 7.1) berücksichtigt:

1. „Langfristszenarien für die Transformation des Energiesystems in Deutschland 3" des Bundesministeriums für Wirtschaft und Klimaschutz (Sensfuß et al. 2021)
2. "Klimaneutrales Stromsystem 2035" (Agora Energiewende, Prognos, Consentec 2022)
3. Modell- und Szenarienvergleich "Deutschland auf dem Weg zur Klimaneutralität 2045" des vom Bundesministerium für Wirtschaft und Forschung (BMBF) geförderten Kopernikus-Projekts ARIADNE (Luderer et al. 2021).

Die Auswahl erfolgte vor allem auf Grund der Datenverfügbarkeit. Die Langfristszenarien (1) konnten wegen noch nicht veröffentlichter Ergebnisberichte zum Zeitpunkt der Arbeiten nicht genutzt werden. Auch die Studie "Klimaneutrales Stromsystem 2035" (2) erwies sich als ungeeignet, da die Datenverfügbarkeit insbesondere in Bezug auf Kostenparameter unzureichend war.

Im Gegensatz dazu beinhaltet der Report "Deutschland auf dem Weg zur Klimaneutralität 2045" (3, im Folgenden kurz "ARIADNE-Report" genannt) die meisten in En4U benötigten Szenariodaten und zeichnet sich zudem durch eine exzellente Datenverfügbarkeit in Form einer offenen und gut dokumentierten Excel-Tabelle aus. Aus diesem Grund wurde der ARIADNE-Report als zentrale Datengrundlage für die Bedatung in En4U genutzt.

### 7.2.2 Verwendete Daten

Aus dem ARIADNE-Report wurden folgende Daten für die Parametrierung von AMIRIS und SOM genutzt:

- Kraftwerkskapazitäten
- Ökonomische Parameter von Kraftwerken (CAPEX, OPEX, Amortisationsdauern)
- Technische Parameter von Kraftwerken (Effizienzen)
- Brennstoffpreise
- Jährliche Strombedarfe

Die Daten sind in Fünfjahresblöcken für die Stützjahre zwischen 2015 und 2050 verfügbar. Die Auswertung basiert auf den Daten gemäß dem jeweiligem Leitmodell des ausbalancierten ARIADNE-Szenarios "8Gt\_Bal" für REMIND, welches keine extreme Nutzung von Wasserstoff oder Strom in den Sektoren vorsieht.

Über das REMix-Modell, das ebenfalls im ARIADNE-Projekt beteiligt war, standen stündlich aufgelöste Verbrauchszeitreihen zur Verfügung, die mit den ARIADNE-Szenariodaten berechnet waren. Über Python-Skripte werden diese für unsere Zwecke angepasst. Andere Skripte werden für die Erzeugung künstlicher Zeitreihen auf Basis der statischen ARIADNE-Szenariodaten eingesetzt, da einige Inputs in AMIRIS in Form von Zeitreihen vorliegen müssen.

Im ARIADNE-Report selbst sind keine Daten zu den Preisen von CO<sub>2</sub>-Zertifikaten enthalten. Daher wurden diese Daten mit einer verwandten Studie der gleichen Autoren abgeglichen (Pietzcker et al. 2021) und dem World Energy Outlook (International Energy Agency (IEA) 2023) entnommen:




Abbildung 12. CO<sub>2</sub>-Preise nach Szenario nach WEO

### 7.2.3 Einbindung der Szenarien in AMIRIS

AMIRIS als zentrales Element des EN4U-Workflows verarbeitet die Szenariendaten in dreifacher Weise. Erstens, durch die ARIADNE-Kraftwerkskapazitäten, die im stochastischen Optimierungsmodell als Startwerte dienen. Sie werden über die Kopplung an AMIRIS weitergegeben und jedes Simulationsjahr upgedatet. Zweitens, über das Diffusionsmodell. Auch hier werden die Szenarienrahmendaten im Modell verarbeitet und an AMIRIS weitergegeben. Drittens, über die Parametrierung der übrigen Daten selbst. In AMIRIS fließen sämtliche weiteren benötigten Daten, wie z. B. Kraftwerkseffizienzen, CAPEX und OPEX-Kosten aus ARIADNE in die Szenarien-Dateien ein, um die Agenten zu konfigurieren.

### 7.2.4 Einbindung der Szenarien in SOM

Den Daten für 2020 zufolge beeinflussten die Brennstoffpreise 59 % der gesamten Nettostromerzeugung in Deutschland, während Kohlenstoff 46 % der gesamten Energieerzeugung ausmachte. Diese Zahlen unterstreichen die entscheidende Rolle der Brennstoff- und Kohlenstoffpreise für langfristige Entscheidungen. Darüber hinaus wies Erdgas, das im Jahr 2020 12 % der gesamten Nettostromerzeugung in Deutschland ausmachte, in den letzten Zeiträumen erhebliche

Schwankungen auf, was zuverlässige Prognosen erschwert. Vor dem Hintergrund dieser Analyse werden die Erdgas- und Emissionspreise aus ökonomischer Sicht als unsichere Parameter behandelt. Wir modellieren diese Unsicherheiten mit Hilfe einer Szenariobaumtechnik. Ein Szenariobaum stellt Unsicherheiten dar, indem er mögliche Pfade von der Anfangs- bis zur Endstufe aufzeigt. In dieser Fallstudie dient ein Jahr als Darstellung des Zeitraums, der als Stufe bezeichnet wird. Wir haben einen rekombinierenden Szenariobaum unter Verwendung der Erdgaspreise aus den Szenarien des ARIADNE-Berichts und der Emissionspreise aus den Szenarien des World Energy Outlook-Berichts 2023 (International Energy Agency (IEA) 2023) erstellt, was insgesamt 43 046 721 Szenarien entspricht.

### 7.3 AMIRIS (DLR)

Neben den o.g. Szenariendaten benötigt AMIRIS weitere Inputdaten. Dies sind im Wesentlichen Lastprofile und Einspeiseprofile erneuerbarer Energien in stündlicher Auflösung für das betrachtete Wetterjahr. Die Lastprofile stehen aus den oben erwähnten REMix-Läufen zur Verfügung, da hier spezifisch für die ARIADNE-Szenarien stündlich aufgelöste Daten verwendet werden können.

### 7.4 Mikromodelle

Für die Mikromodelle werden meteorologische Daten als Eingangsgröße benötigt. Diesbezüglich sind insbesondere die Außentemperatur sowie die Solarstrahlung von Relevanz, welche in stündlicher Auflösung vorliegen müssen. Diese Daten wurden der ERA5-Reanalyse entnommen (Hersbach et al. 2024; C3S 2018). Basierend auf diesen beiden Daten wurden Ertragsprofile für PV-Strom und geneigte Sonneneinstrahlung (benötigt für das Mikromodell Wärmepumpen) mit der Software *pvl* (Anderson et al. 2023) berechnet.

Für das Mikromodell E-Pkw wurden die Fahrprofile aus dem oft verwendeten MID-Datensatz (siehe Abschnitt 3.4) mit den Diffusionsmodellen (siehe Abschnitt 4) verschnitten. Dies wurde dadurch erreicht, dass die Schnittmenge der haushaltsspezifischen Informationen der MID und denjenigen Haushalten aus der Haushaltsumfrage, die E-Pkw besitzen, gebildet wurde. D.h. es werden nur Fahrprofile für genau diejenigen Haushaltstypen verwendet, die in der Umfrage ein E-Pkw besitzen.

### 7.5 SOM (IOR)

Wir modellieren das deutsche Stromsystem mit Daten aus dem Jahr 2020 nach dem ARIADNE REMIND-Referenzszenario (Luderer et al. 2021). Wir betrachten die folgenden Technologien: Kohle, Erdgas, Kernkraft, Öl, Bioenergie, Geothermie, Wasserkraft, Photovoltaik (PV), Windkraft und Speicher. Während des Planungshorizonts ist ein jährliches Ausscheiden aller Technologien zulässig. Sechzehn Gebiete in Deutschland werden in unsere Fallstudie integriert. Diese Darstellung vereinfacht das Problem. Es wird davon ausgegangen, dass sich alle Technologien zentral in jeder Zone befinden. Fossile Stromerzeuger, die dieselbe Technologie nutzen, haben unabhängig von ihrem Standort identische Parameter. Solar- und Windtechnologien haben je nach Standort unterschiedliche stündliche Kapazitätsfaktoren. Wir haben meteorologische Daten von 2018 bis 2020 zusammengestellt, um ein repräsentatives Jahr zu schaffen. Als repräsentatives Jahr haben wir die stündlichen Kapazitätsfaktoren für jede Stunde und jeden Tag kombiniert, um die Kapazitätsfaktoren für jede Zone zu berechnen. Wasserkraft- und Bioenergiesysteme, wie Wind- und Solarenergie, haben stündliche Kapazitätsfaktoren, die nicht vom Standort abhängig sind. Es wird angenommen, dass die Kapazitätsfaktoren über den Planungshorizont konstant bleiben.

## 7.6 Diffusionsmodell (IIP)

Für das Bass-Diffusionsmodell werden in erster Linie historische Daten der jährlichen Adaptionen benötigt. Diese Daten wurden dem Marktstammdatenregister (für PV-Adoptionsraten) sowie dem Kraftfahrtbundesamt (für E-Pkw-Adoptionsraten) entnommen. Die Szenarien des E-Pkw Diffusionsmodells, welche sich darin unterscheiden, wie sich der Mobilitätssektor und insbesondere der Pkw-Markt zukünftig entwickeln, werden aus Studien des Fraunhofer Instituts für System- und Innovationsforschung (ISI) sowie des Wuppertal Instituts für Klima, Umwelt und Energie übernommen (Schade et al. 2020; Rudolph et al. 2017). Darüber hinaus wurden die Lastprofile der Typhaushalte mithilfe des LoadProfileGenerators (Pflugradt und Muntwyler 2017) generiert.

Im Rahmen der Wirtschaftlichkeitsbetrachtung wurden, neben den unter 4.2 beschriebenen Annahmen, prognostizierte Entwicklungen der Investitionsausgaben von PV und PVS berücksichtigt. Hierzu wurden die Daten aus Ram et al. (2022) verwendet.

Die Kopplung mit AMIRIS erfolgt über die Bereitstellung der Gesamtzahl der Haushalte, der Adoptionsraten der PVS-Anlagen über die Jahre, und deren technischen Daten bei optimalem Betrieb (Größe und Speichergröße). Diese Daten sind einerseits die Basis für die Mikromodelle PVS und E-Pkw, und andererseits für die ML-Algorithmen.

## 8 Ergebnisse

### 8.1 Ergebnisse AMIRIS mit integrierten ML-Modellen (DLR)

Es ist ein bekanntes Problem bei Optimierungsmodellen, dass der Kraftwerkspark zwar eventuell volkswirtschaftlich kostenoptimal berechnet wird, aus betriebswirtschaftlichen Gründen jedoch so nicht realistisch ist, da Akteure ihren Gewinn optimieren, aber nicht den Gewinn insgesamt. Dabei unterliegen sie Unsicherheiten, unterschiedlichen Informationen, usw. Dieses Problem löst die Kopplung von AMIRIS und dem SOM – sowohl die Optimierung wird durchgeführt, als auch der jährliche „Plausibilitätscheck“, der als Korrektur an das SOM zurückgespielt wird und als Basis für die Berechnung des nächsten Jahres dient. Die Parametrisierung folgt Abschnitt 7.2, d.h. den Daten des ARIADNE-Projekts (Luderer et al. 2021).




Abbildung 13. Vergleich der Systemkosten zwischen Referenzszenario und stochastisch optimiertem Szenario

Die exakten Ergebnisse dieser Kopplung sind im Detail in Abschnitt 8.7 dargestellt.




Abbildung 14. Differenz der Systemkosten zwischen ARIADNE Szenario und ARIADNE Szenario plus PVS und E-Pkw Agenten

Abbildung 14 vergleicht die Stromsystemkosten, also die Kosten für den Kraftwerkseinsatz für ein Basisszenario von ARIADNE mit einer erweiterten Version, die eine zusätzliche Modellierung von Haushalten mit Photovoltaiksystemen mit Speicher (PVS) und Elektrofahrzeugen (E-Pkw) umfasst. Diese Erweiterung stellt die Implementierung der Kopplung von AMIRIS mit den ML-Modellen dar.

Durch die Einführung dieser Agenten wird dem System ein zusätzlicher Strombedarf hinzugefügt, bei dem generell eine Erhöhung der Systemkosten erwartet würde. Die Ergebnisse zeigen Schwankungen über die Zeit hinweg, wobei die Unterschiede in den Kosten zwischen positiven und negativen Werten variieren. Negative Werte zeigen an, dass das erste Szenario niedrigere Systemkosten aufweist, während positive Werte darauf hinweisen, dass die Kosten im ersten Szenario im Vergleich zur erweiterten Version höher sind. Insgesamt zeigt die Abbildung, dass das zweite Modell trotz des zusätzlichen Bedarfs eine durchgehende Reduktion der Systemkosten erzielt. Sie sind ein Indikator dafür, wie ML-Modellierung auf den Markt, v.a. Elektrizitätspreise und Gesamtkosten, wirkt.

Diese Reduktion deutet darauf hin, dass die Integration von Haushalten mit PVS und E-Pkw den Ausgleich fluktuierender Produktion und Nachfrage verbessern und Kosten senken kann. Zudem unterstreicht dies die Bedeutung einer expliziten Modellierung von Haushalten mit PVS und E-Pkw, da ihre komplexen Interaktionen mit dem Strommarkt erfasst werden und eine genauere Bewertung ihrer Auswirkungen auf die Gesamtleistung des Systems ermöglicht wird.

## 8.2 Ergebnisse Mikromodell Photovoltaik + Speicher (PVS) (DLR)

Im Folgenden präsentieren wir die Ergebnisse des PVS-Mikromodells, das die Interaktion (Ein- und Auspeisung) einzelner Haushaltstypen für ein bestimmtes Jahr und einen bestimmten Ort optimiert, um die gesamten Energiekosten zu minimieren. Diese Ergebnisse spielen für die Modellkopplung eine Rolle, insbesondere für die Bestimmung der Gesamtlast, weil PVS-Systeme durch ihre Ein- und Auspeisung Preise teilweise stark beeinflussen.

Zunächst skizzieren wir die Daten und Parameter, die im Optimierungsprozess verwendet werden. Dazu gehören Eingabedaten, die für den jeweiligen Haushaltstyp spezifisch sind, wie die installierte PV-Kapazität, Speicherkapazität und der Energiebedarf des Haushalts, die alle als Zeitreihen für das Zieljahr bereitgestellt werden. Zusätzlich verwendet das Modell eine PV-Ertragspotential-Zeitreihe, die spezifisch für das Jahr und den Standort ist, sowie eine Zeitreihe der Marktstrompreise. Aus den Marktpreisen berechnet das Modell die Einkaufspreise für Endverbraucher und die Verkaufspreise auf Basis vordefinierter Endverbraucher-Modellen.

Der Optimierungsprozess nutzt ein Prognosefenster von 24 Schritten (entsprechend 24 Stunden bei stündlicher Auflösung) für die Eingabevariablen: PV-Ertragspotential, Strompreis und Haushaltsnachfrage.

Geeignete Wetterzeitreihen sind für das PVS-Mikromodell von entscheidender Bedeutung. Zu diesem Zweck wurden vier repräsentative Standorte in Deutschland ausgewählt (siehe auch Abschnitt 3.5.2).

Abbildung 15 zeigt das Ertragspotential dieser vier Standorte: Kiel, Münster, München und Würzburg.




Abbildung 15. Vergleich der Verteilung der Ertragspotentiale der vier Referenz-Wetterstandorte

Die folgende Abbildung zeigt dagegen nur einen Wetterstandort, Würzburg:

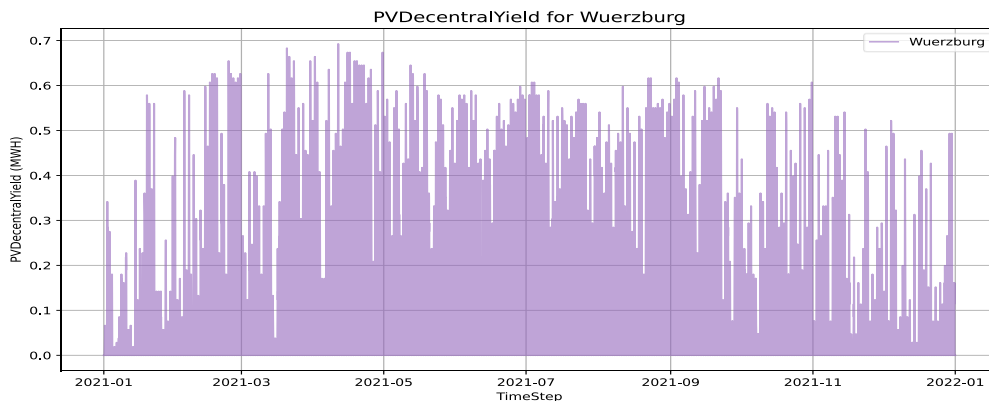


Abbildung 16. Verteilung des Ertragspotentials in Würzburg über das Jahr

Diese Standorte veranschaulichen die geografische Variation des PV-Ertragspotentials aufgrund von Unterschieden in der Sonneneinstrahlung und den Wetterbedingungen. Unter den vier Standorten weist Würzburg das durchschnittlich höchste Ertragspotential auf, was es zu einer repräsentativen Wahl für die weitere Analyse macht. Daher wird sich die Ergebnisdarstellung des PVS-Mikromodells auf Würzburg konzentrieren, um die Ergebnisse zu veranschaulichen.

Während der Standort eine entscheidende Rolle für das PV-Ertragspotenzial spielt, beeinflussen auch haushaltsspezifische Merkmale die optimierte Netzeinspeisung. Abbildung 17 zeigt die optimierte Netzeinspeisung von drei verschiedenen Haushaltstypen, nämlich MH2, MH9 und MH10, die im Referenzjahr 2021 in Würzburg mit einem PVS-System ausgestattet waren. Diese drei Haushaltstypen sind die einzigen, die im Jahr 2021 eine Diffusion größer als null aufweisen.




Abbildung 17. Optimierte individuelle Netzeinspeisung der Haushaltstypen MH2, MH9 und MH10 in Würzburg (2021)

Wie in Abbildung 17 dargestellt, hat der Haushaltstyp einen deutlichen Einfluss auf die optimierte Netzeinspeisung. Unterschiede in der installierten PV-Kapazität, der Speicherkapazität und den Haushaltslastprofilen führen zu unterschiedlichen Interaktionsmustern mit dem Netz. Dies unterstreicht die Bedeutung haushaltsspezifischer Merkmale in der Energiesystemmodellierung.

Über die Optimierung einzelner Haushalte hinaus spielt das Diffusionsmodell eine wichtige Rolle bei der Gestaltung der gesamten Netzeinspeisung auf Bevölkerungsebene. Abbildung 18 zeigt die aggregierte Netzeinspeisung aller deutschen Haushalte mit PVS-Systemen, basierend auf den Wetterdaten von Würzburg als repräsentativem Standort für die gesamte Bevölkerung im Jahr 2021.




Abbildung 18. Aggregierte Netzeinspeisung aller deutschen PVS-ausgestatteten Haushalte basierend auf Wetterdaten von Würzburg (2021)

Die Aggregation ergibt sich aus den optimierten Netzeinspeisungen einzelner Haushalte (Abbildung 17) in Kombination mit den Diffusionsdaten der Haushalte für 2021. Dieses aggregierte Verhalten stellt die Zielvariable dar, die unser ML-Vorhersagemodell erlernen und vorhersagen soll.

Die Leistung der PVS-Systeme unterscheidet sich allerdings deutlich pro Standort. Die folgende Abbildung zeigt diese deutlich sichtbaren Unterschiede in der Einspeisung (negative Werte) und Entnahme (positive Werte) der PVS-Systeme im Vergleich:



### 8.3 Ergebnisse Mikromodell Wärmepumpen (DLR)

Im Folgenden werden exemplarisch die Ergebnisse des Mikromodells Wärmepumpen für eine Fallstudie des Energiesystems in Deutschland für das Jahr 2040 dargestellt, die für das Projekt berechnet wurde (siehe 11.2 Veröffentlichungen). Dabei wird angenommen, dass in Deutschland 11 Mio. Wärmepumpen installiert sind, die unter dynamischen Strompreisen betrieben werden. Hierzu wurde das Mikromodell Wärmepumpen mit AMIRIS gekoppelt.

Um die Auswirkungen unterschiedlicher Betriebsweisen zu analysieren, werden folgende Fälle definiert:

- **Inflex:** Inflexible Wärmepumpen-Betriebsweise. Dabei wird tagsüber eine konstante Raumtemperatur von 20°C angenommen. Der Warmwasserspeicher wird konstant auf Bereitschaftstemperatur (55°C) gehalten. Dieser Fall dient als Referenz.
- **ModFlex:** Flexible Wärmepumpen-Betriebsweise mit moderater Nutzertoleranz. Hierbei darf die Tages-Raumtemperatur um 1°C gegenüber der Referenz nach oben und unten abweichen (also 19-21°C). Die Temperatur im Warmwasserspeicher darf zwischen 55°C und 70°C variieren.
- **HighFlex:** Flexible Wärmepumpen-Betriebsweise mit hoher Nutzertoleranz. Hierbei darf die Tages-Raumtemperatur um 2°C gegenüber der Referenz nach oben und unten abweichen (also 18-22°C). Die Temperatur im Warmwasserspeicher darf zwischen 55°C und 70°C variieren.

In allen drei Fällen wird eine Nachtabsenkung angenommen, die 90% der Tagessolltemperatur entspricht. Details zu dieser Fallstudie sind der Publikation (Sperber et al. 2024) zu entnehmen.

Zur Veranschaulichung des Modellverhaltens zeigt Abbildung 19 die Betriebseigenschaften einer flexiblen Wärmepumpe für den Fall *ModFlex* im Vergleich zu dem ihrer inflexiblen Referenz. Die Abbildung zeigt den simulierten Stromverbrauch („*Electricity consumption*“) einer Luft/Wasser-Wärmepumpe in einem sanierten Einfamilienhaus aus den 1960er Jahren, die für die Raumheizung und die Warmwasserbereitung an zwei Wintertagen genutzt wird. Zudem werden die entsprechenden dynamischen Strompreise („*RTP*“) sowie Innenlufttemperatur („*Indoor air temperature*“) und Warmwasserspeichertemperaturen („*Temperature of DHW storage tank*“) dargestellt.

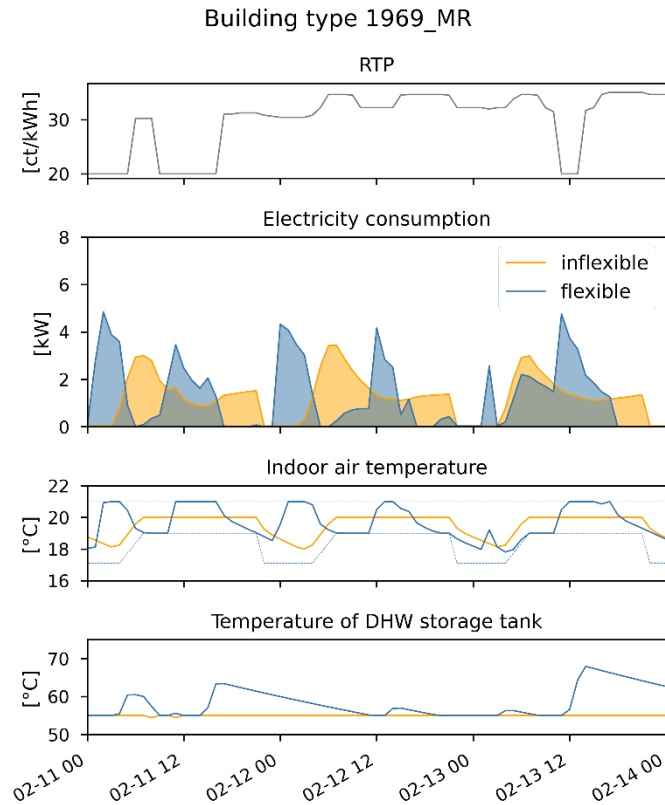


Abbildung 19. Exemplarischer Wärmepumpeneinsatz gemäß dem Mikromodell Wärmepumpen

Der unflexible Betrieb (gelbe Linien) ist von den Preisen unabhängig, während der flexible Betrieb (blaue Linien) zu einer Verlagerung des Stromverbrauchs in Zeiten niedrigerer Preise führt. Die im Modell hinterlegten zulässigen Grenzwerte sind in der Abbildung als gestrichelte Linien dargestellt.

Der jährliche Stromverbrauch von Luft/Wasser-Wärmepumpen wird in Abbildung 20 dargestellt. Auf der x-Achse sind verschiedene Gebäudetypen aufgetragen, die sich durch ihr Baualter unterscheiden (links: alt, rechts: neu). Zusätzlich werden die Gebäudetypen danach unterschieden, ob sie sich im Ist-Zustand („SQ“) oder im sanierten Zustand („MR“) befinden. Darüber hinaus wird der Stromverbrauch für unterschiedliche Nutzertoleranzen differenziert. Die Fehlerbalken zeigen den Einfluss unterschiedlicher Wetterjahre.

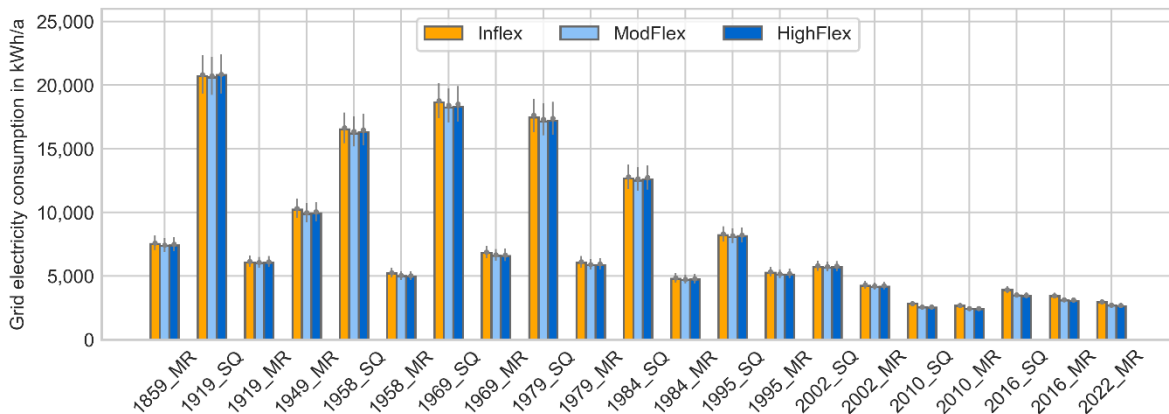


Abbildung 20. Jahresstromverbrauch von Luft/Wasser-Wärmepumpen für verschiedene Gebäudetypen und Nutzertoleranzen

Der Stromverbrauch variiert stark zwischen den Gebäudetypen und ist bei unsanierten und älteren Gebäuden mit bis zu 20 MWh/a besonders hoch. Im Gegensatz dazu liegt der jährliche Stromverbrauch in heutigen Neubauten nur bei ca. 2 MWh/a. Unterschiede zwischen den Nutzertoleranzen sind kaum feststellbar.

Bei Betrachtung der jährlichen Stromkosten für den Wärmepumpenbetrieb werden die Unterschiede zwischen den Nutzertoleranzen deutlich (Abbildung 21). Während die Kosten bei *Inflex* proportional zum Jahresstromverbrauch sind, fallen sie bei *ModFlex* und *HighFlex* geringer aus. Dies ist auf die Verschiebung des Strombezugs in Zeiten niedriger Strompreise bei der flexiblen Fahrweise zurückzuführen, die bei höherer Nutzertoleranz besonders gut ausgenutzt werden kann. Die Einsparpotentiale durch flexible Fahrweise liegen, je nach Gebäudetyp und Nutzertoleranz, zwischen 200 € und 600 € im Jahr.

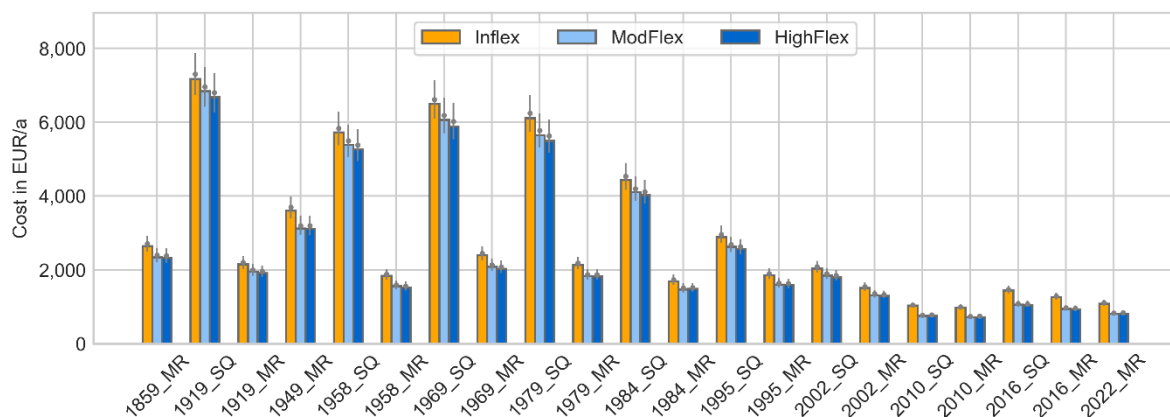


Abbildung 21. Jährliche Stromkosten von Luft/Wasser-Wärmepumpen für verschiedene Gebäudetypen und Nutzertoleranzen

Abbildung 22 zeigt die aggregierte Last flexibler Wärmepumpen (Fall *ModFlex*) im Verlauf des Jahres 2040. Lastspitzen sind im Februar zu beobachten und betragen im betrachteten Szenario über 60 GW. Die aggregierten Lastzeitreihen für verschiedene Wetterstandorte dienen dem Training der neuronalen Netze, wie weiter oben beschrieben.




Abbildung 22. Aggregierter Stromverbrauch von Wärmepumpen im Szenario 2040 (Wetterjahr 2019)

Zusammenfassend zeigen die Ergebnisse, dass die Betriebsweisen und die daraus resultierenden Stromverbräuche von Wärmepumpen stark vom Gebäudetyp abhängen und die Stromkosten zusätzlich durch das Nutzerverhalten beeinflusst werden können. Das Mikromodell ist in der Lage, diese Zusammenhänge adäquat abzubilden. Zudem ermöglicht die bottom-up-Modellierung auf Basis

repräsentativer Gebäude die Analyse aggregierter Marktauswirkungen, die durch den Einsatz einer Vielzahl von Wärmepumpen entstehen.

Die hohe Rechenintensität des Modells stellt jedoch einen Nachteil dar. Für ein Szenario in viertelstündlicher Auflösung und mit 20 Gebäudetypen sowie vier Wetterstandorten ist mit einer Rechenzeit von ca. 1–2 Stunden zu rechnen (vgl. Sperber et al. (2024)). Daher empfiehlt sich der Einsatz von Neuronalen Netzen zur Abstraktion des Mikromodells.

#### 8.4 Ergebnisse Mikromodell E-Mobilität (DLR)

Im Folgenden werden exemplarisch die Ergebnisse des Mikromodells Elektromobilität für zwei Haushaltcluster dargestellt. Dabei wird angenommen, dass in Deutschland 41 Millionen Haushalte existieren, von denen 2,5% Elektrofahrzeuge besitzen, die flexibel geladen werden.

Die Analyse der Haushaltscluster mit Elektrofahrzeugen zeigt zwei unterschiedliche Typen. Cluster 2 repräsentiert Haushalte, die typischerweise aus Angestellten bestehen (EMP = 4) und in freistehenden Einfamilienhäusern (BUI = 1) wohnen. Die Altersgruppe der Haushaltsmitglieder liegt überwiegend zwischen 25 und 35 Jahren (AGE = 4). Diese Haushalte weisen ein hohes Bildungsniveau auf, mit einem Fachhochschul- oder Hochschulabschluss (EDU = 8), und verfügen über ein monatliches Nettoeinkommen von 5000 € oder mehr (INC = 8). Regional befinden sich diese Haushalte überwiegend im Norden Deutschlands (REG = 3). Die Haushaltsgröße beträgt fünf oder mehr Personen (HHS = 5), und der Wohnsitz befindet sich typischerweise in einer Landgemeinde mit weniger als 5000 Einwohnern (LOC = 1). Cluster 14 repräsentiert hingegen Haushalte, die ebenfalls aus Angestellten bestehen (EMP = 4), jedoch in Reihenhäusern (BUI = 3) wohnen. Die Altersgruppe der Haushaltsmitglieder liegt ebenfalls zwischen 25 und 35 Jahren (AGE = 4). Im Vergleich zu Cluster 2 ist das Bildungsniveau dieser Haushalte etwas niedriger und entspricht einer abgeschlossenen Lehre (EDU = 5). Das monatliche Nettoeinkommen liegt zwischen 2000 € und 2500 € (INC = 4). Auch diese Haushalte befinden sich im Norden Deutschlands (REG = 3), jedoch unterscheidet sich die Haushaltsgröße mit vier Personen (HHS = 4) sowie die Wohnsitzgröße, die sich typischerweise in Großstädten mit 100.000 oder mehr Einwohnern befindet (LOC = 4). Diese beiden Cluster verdeutlichen, wie sich die sozioökonomischen und strukturellen Merkmale von Haushalten mit Elektrofahrzeugen in Deutschland je nach Lebensstil und Standort unterscheiden können. Cluster 2 macht 1,5 % der insgesamt 41 Millionen Haushalte in Deutschland aus, was etwa 615.000 Haushalten entspricht. Cluster 14 repräsentiert hingegen 1 % der Haushalte, also etwa 410.000 Haushalte.

Um das Modell zu veranschaulichen, zeigen Abbildung 23 und 24 das Verhalten des flexiblen Ladens für beide Cluster mit Elektrofahrzeugen. Diese Abbildungen zeigen den Stromverbrauch („Electricity consumption“) für Fahrzwecke, die verfügbare Abschlussleistung („Available charging power“) (hauptsächlich Heimpladen, mit begrenztem Arbeitsladen, wie in Tabelle 4 angegeben), den Strompreis („Electricity price“) und die resultierende optimierte Ladebelastung („Charging load“) basierend auf dem Strompreis.

Die ersten beiden Profile („Electricity consumption“ und „Available charging power“) sind Ausgaben des Modells `venco.py` und werden anschließend zusammen mit der Strompreissetreihe als Eingabe in ein Optimierungsmodell verwendet, um die optimierte Ladebelastung („Charging load“) zu berechnen.

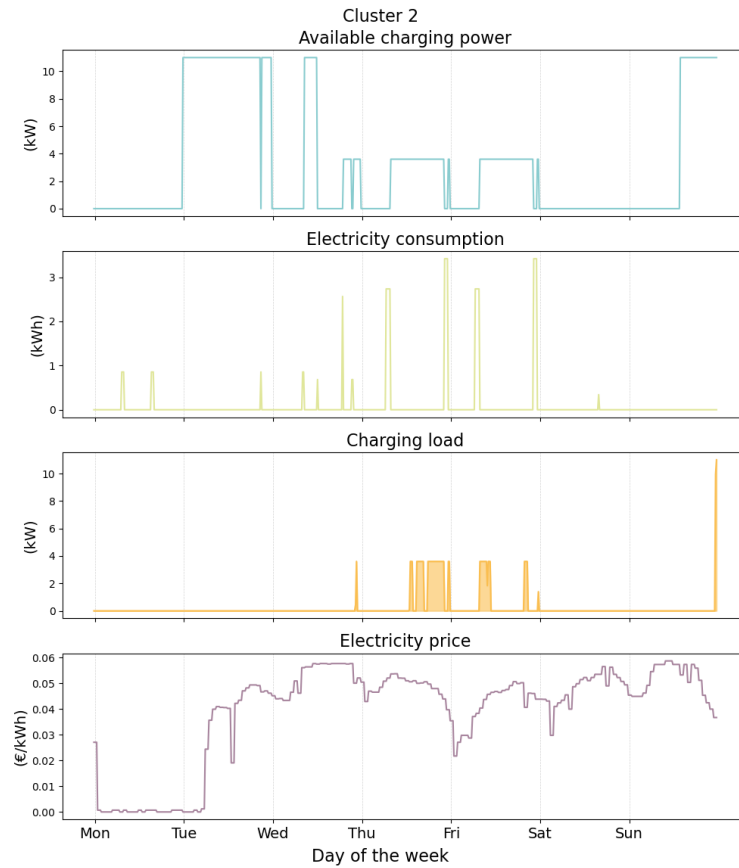


Abbildung 23. Beispielhaftes Ergebnis für flexibles preisbasiertes Laden für Cluster 2.

Eine interessante Beobachtung für Cluster 2 zeigt sich am Donnerstag, wo die Ladeleistung deutlich ansteigt. Dies steht im Zusammenhang mit längeren Fahrten, die im Laufe des Tages unternommen wurden, was auch im Muster des Verbrauchs erkennbar ist. Nach diesen längeren Fahrten (die vermutlich die Batterie des Fahrzeugs entleeren) steigt die Ladeleistung erheblich an, um die Batterie wieder aufzuladen, besonders in den späten Abend- oder Nachtstunden.

Die jährlich gefahrenen Kilometer und damit der jeweilige Stromverbrauch für Fahrzwecke liegen im gleichen Größenbereich für beide Cluster, wobei sich die Cluster hauptsächlich in ihren Mobilitätsmustern unterscheiden. Cluster 2 weist längere Fahrten an den Wochentagen auf, während Cluster 14 regelmäßig kürzere Fahrten während der Woche und eine größere Fahrstrecke an den Sonntagen zeigt. Diese Unterschiede führen zu Abweichungen bei der Ladebelastung, wobei Cluster 2 überwiegend mitten in der Woche über Nacht lädt, während Cluster 14 zu Beginn des Wochenendes über längere Zeiträume lädt.

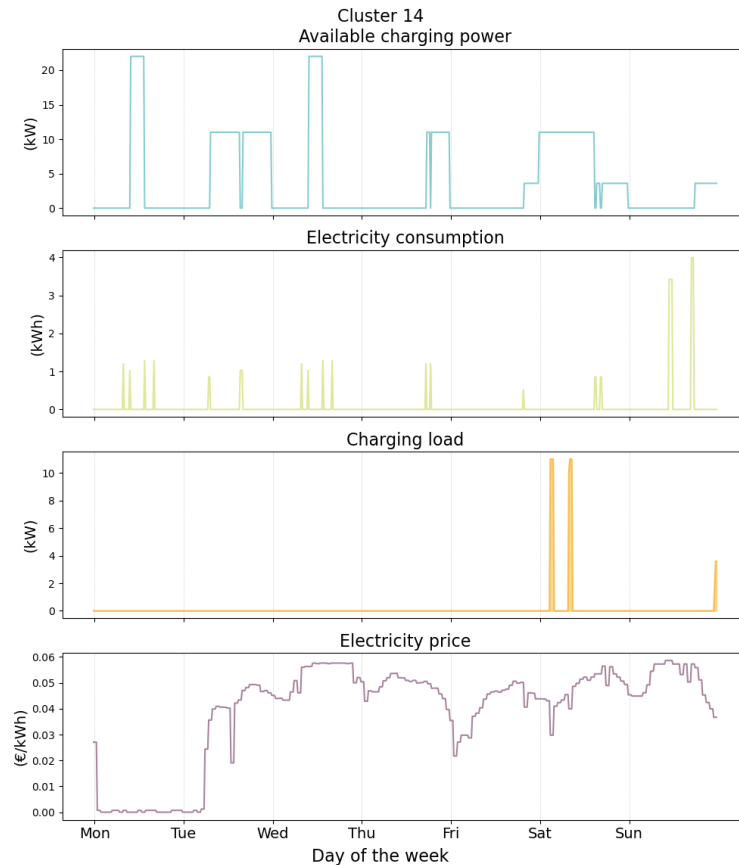


Abbildung 24. Beispielhaftes Ergebnis für flexibles preisbasiertes Laden für Cluster 14.

Die Ergebnisse zeigen, dass die Mobilitätsmuster und die daraus resultierende Ladelast von Elektrofahrzeugen stark vom Haushalts- und Gebäudetyp abhängen. Dieses Verhalten kann jedoch durch die Stromkosten beeinflusst werden. Das Mikromodell ist in der Lage, diese Zusammenhänge abzubilden. Darüber hinaus ermöglicht die Bottom-up-Modellierung auf Basis repräsentativer Mobilitätsmuster die Untersuchung des aggregierten Verbrauchs und der damit verbundenen Auswirkungen.

## 8.5 Ergebnisse Maschinelles Lernen (DLR)

Stellvertretend für die drei ML-Modelle für PVS, E-Pkw und Wärmepumpen werden hier die Ergebnisse für PVS gezeigt, die demonstrieren, dass eine Ersetzung individueller Haushaltsentscheidungen durch ein ML-Modell möglich ist. Damit ist eine hohe Flexibilität für AMIRIS gewonnen, da über diese Schnittstelle jeder Agent eine dezidierte, präzise Modellierung mit ML zur Verfügung gestellt bekommen kann. Dies erhöht die Genauigkeit der Simulation.

Die folgende Abbildung zeigt zunächst das Training für PVS:

Training History of the PV ML Model




Abbildung 25. Training mit 4-facher Cross-validation

Es fällt auf, dass der Validierungsfehler bei jeder Änderung (4x) der Zusammensetzung des Trainingsdatensatzes sinkt, während der Trainingsfehler ansteigt. Das spiegelt die Generalisierungsleistung wider und ist so erwartet und gewollt.

Insgesamt liegt der mittlere absolute Fehler (MAE) bei ~ 680 MWH. Bei einer Spanne zwischen dem Minimum von -22 949 MWH und dem Maximum +11 126 MWH ist das ein gutes Ergebnis (siehe z. B. Abbildung 18 für Würzburg, einem repräsentativen Wetterstandort). Die Einspeisung und Stromentnahme von PVS-Haushalten kann also insgesamt gut durch ML abgebildet werden, siehe Tabelle 9.

Tabelle 9. Fehler pro Modell

| Name Modell             | MSE          | RMSE    | MAE    | MinVal   | MaxVal    |
|-------------------------|--------------|---------|--------|----------|-----------|
| Photovoltaik + Speicher | 1.405.854,05 | 1185,68 | 685,03 | -6501,25 | 10.369,27 |
| Wärmepumpen             | 621.753,16   | 788,51  | 540,80 | 0,0      | 5130,84   |
| E-Mobilität             | 350.259,46   | 591,82  | 151,69 | 0,0      | 7157,09   |

Als Trend über die Zeit sehen die Ergebnisse wie in der folgenden Abbildung gezeigt aus:

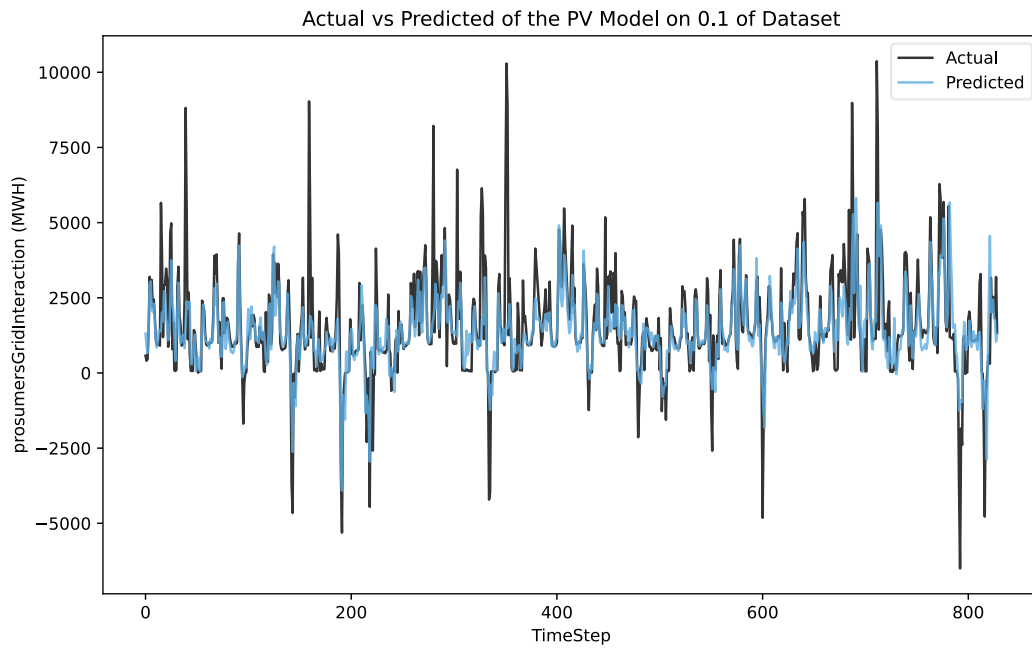


Abbildung 26. Tatsächliche Einspeisung+Entnahme PVS vs. vorhergesagte Werte

Man sieht, dass die Muster gut getroffen werden, während die Extremwerte systematisch unterschätzt werden. Das ist allerdings ein inhärentes Problem vieler Zeitreihenvorhersagen und kann nicht komplett vermieden werden. Deshalb sieht die Fehlerverteilung auch wie folgt aus:

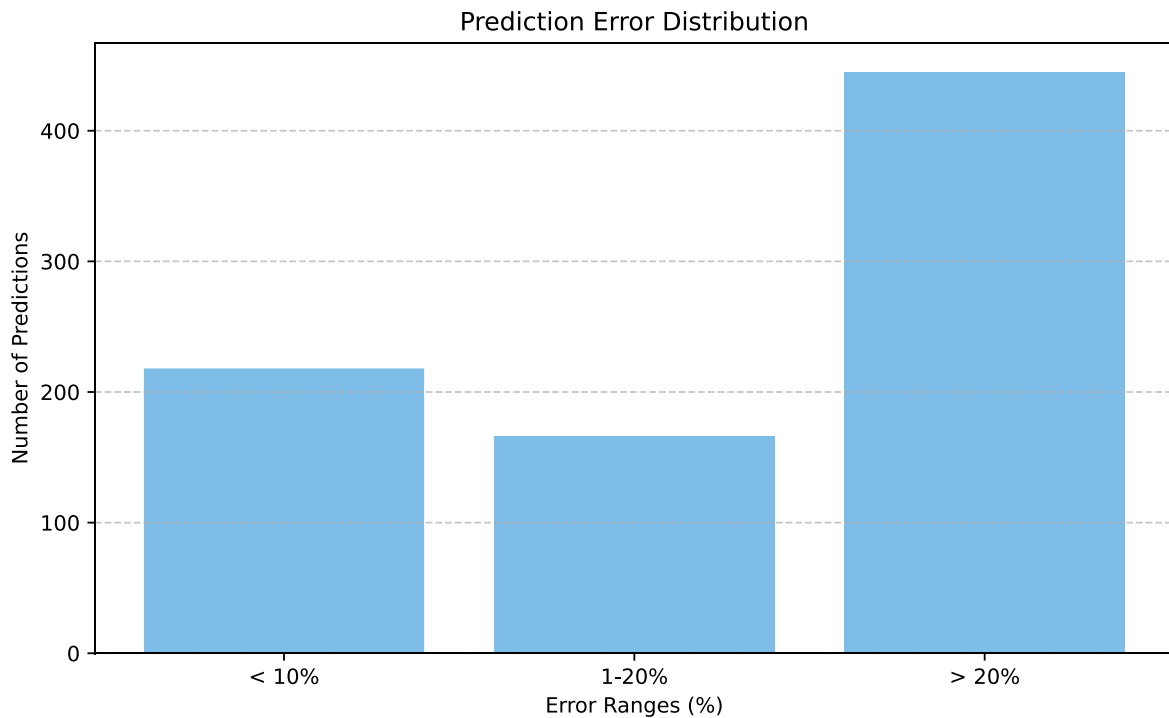


Abbildung 27. Fehlerverteilung nach prozentualer Abweichung



Wenn man diese Fehler noch einmal aufschlüsselt, zeigt sich, dass der Großteil der Fehler tatsächlich aus dieser Unterschätzung stammt, wie die nächste Abbildung zeigt:




Abbildung 28. Art der Fehlerverteilung

Insgesamt lässt sich konstatieren, dass die ML-Modelle die Muster in den Zeitserien gut treffen. Die prinzipielle Möglichkeit der Ersetzung rechenintensiver Modelle auf individueller Ebene mit trainierten neuronalen Netzen, die in der Produktion praktisch keinerlei Rechenzeit mehr benötigen, ist damit gezeigt. Die Ergebnisse zeigen auch, dass bezüglich der Modellqualität, also der Genauigkeit der Vorhersagen noch Entwicklungsbedarf gegeben ist.

## 8.6 Ergebnisse Diffusionsmodell (IIP)

Die Modellierung geeigneterer Referenzhaushalte führte zu 19 verschiedenen Haushaltsgruppen, die in Bezug auf technologierelevante Charakteristika repräsentativ für die deutsche Bevölkerung sind. Von diesen Gruppen nutzen derzeit lediglich drei Referenzhaushalte Photovoltaikanlagen, ein Haushalt Photovoltaikanlagen zusammen mit Batteriespeicher sowie jeweils zwei Haushalte Wärmepumpen und Elektrofahrzeuge. Hervorzuheben ist, dass nur ein Referenzhaushalt alle vier Technologien verwendet. Diese Gruppe repräsentiert lediglich 1,6 % der deutschen Haushalte. Besonders relevant für die zukünftige Verbreitung der betrachteten Technologien sind dabei neun der identifizierten 19 Referenzhaushalte. Diese zeichnen sich insbesondere dadurch aus, dass sie in Einfamilien-, Zweifamilien- oder Reihenhäusern wohnen, die sich im Eigentum eines oder mehrerer Haushaltsmitglieder befinden. Sie kommen dadurch als primäre Zielgruppe für die weitere Technologieadoption infrage. Die entsprechenden neun Haushaltsgruppen repräsentieren dabei etwa 37% deutscher Haushalte. Außerdem haben fünf dieser Haushaltsgruppen in der repräsentativen Befragung eine sehr hohe oder hohe Installationsabsicht von PV- und PVS-Anlagen signalisiert.

Darauf aufbauend wurden für die neun geeigneten Referenzhaushalte mithilfe der Kapitalwertberechnung (Kapitel 4.2), unter Berücksichtigung haushaltsspezifischer Merkmale, die

wirtschaftlich optimalen Systemkonfigurationen aus Photovoltaik (PV) und Photovoltaikspeichern (PVS) ermittelt. Die Analyse zeigt, dass für alle betrachteten Haushaltstypen die maximal betrachtete PV-Systemgröße von 10 kWp als wirtschaftlich optimal einzustufen ist. Die wirtschaftlich optimale Größe der Batteriespeichersysteme variiert jedoch je nach Energieverbrauch der Haushalte. Für größere Haushalte mit hohem Strombedarf, insbesondere bei zusätzlicher Nutzung einer Wärmepumpe sowie eines E-Pkws, ist durchgehend die maximale PVS-Kapazität von 10 kWh ökonomisch sinnvoll, während kleinere Haushalte geringere Speichergrößen zwischen 4,5 und 7 kWh wählen.

Ebenso wurde anhand einer Sensitivitätsanalyse der Einfluss von Endkundenstrompreisentwicklungen und Technologiekosten auf Investitionsentscheidungen untersucht. Dabei zeigt sich, dass ein Strompreisanstieg zu mehr Investitionen in größere Batteriespeicher führt, während sinkende Technologiekosten ebenfalls größere Batteriespeicher begünstigen und zu höheren Kapitalwerten führen.

Zusätzlich wurde die Diffusion von privaten PV-Anlagen unter Berücksichtigung von drei Szenarien geschätzt, welche nachstehend abgebildet werden.




Abbildung 29. Diffusionsverläufe der E-PV für drei untersuchte Szenarien

Durch die Verknüpfung der optimalen Systemgrößen mit den prognostizierten Diffusionszahlen ergibt sich ab dem Jahr 2024 bis einschließlich 2045 eine kumulierte Gesamtkapazität der PV-Neuinstallationen bei den betrachteten Gebäuden im Haushaltssektor von 105,3 GW sowie 70,6 GWh kumulierte Speicherkapazität.

Für das Diffusionsmodell der E-Pkw wurden geeignete Parameter unter Berücksichtigung von vier Szenarien für das maximale Marktpotential des Modells geschätzt. Auf Basis dessen wurde schließlich der zukünftige Diffusionsverlauf batterieelektrischer Pkw unter privaten Personen in Deutschland

modelliert. Der Diffusionsverlauf ist in der nachstehenden Abbildung für jedes der vier Szenarien dargestellt. Dabei liegt die maximale Adoptionsrate für alle vier Szenarien zwischen Ende 2027 und Ende 2029.

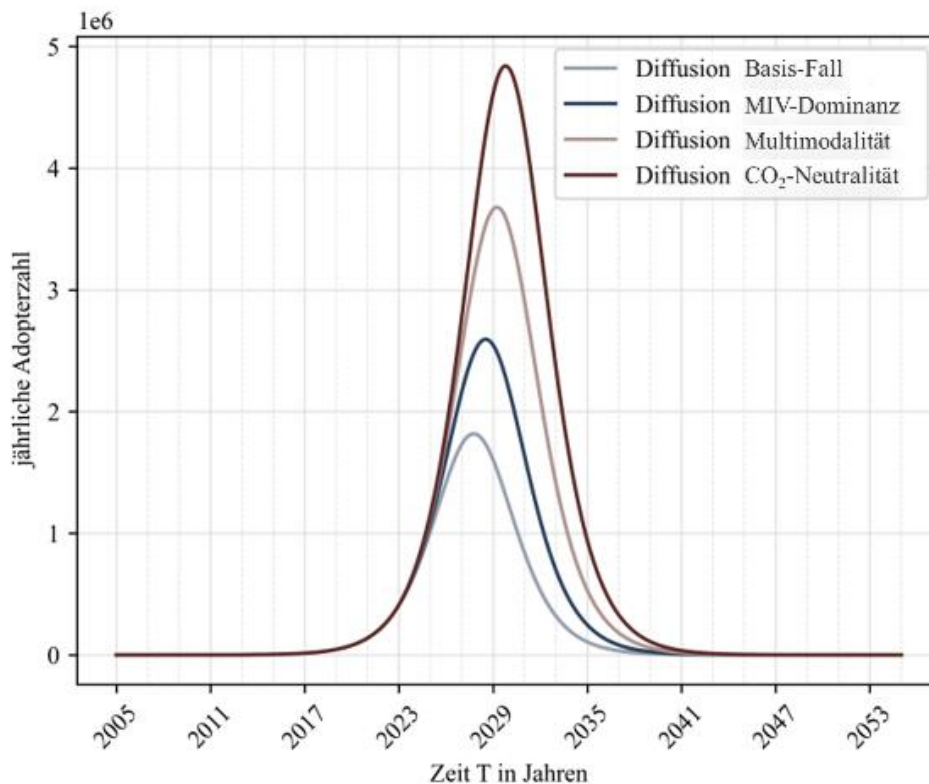


Abbildung 30. Diffusionsverläufe der E-Pkw für vier untersuchte Szenarien

Zuletzt zeigt die ergänzende Analyse zur Wirtschaftlichkeit von Elektrofahrzeugen in Kombination mit PV-Anlagen deutliche wirtschaftliche Vorteile für die kombinierte Nutzung. Der erhöhte Eigenverbrauch führt zu signifikanten Einsparungen bei den Energiekosten sowie einer Steigerung des Kapitalwerts im Vergleich zur alleinigen PV-Installation. Insbesondere Haushalte mit hohem Strom- und Mobilitätsbedarf erzielen mit der PV-und-E-Pkw-Kombination einen erheblichen Anstieg des Kapitalwerts, wobei auch die Referenzhaushalte mit geringerer Fahrzeugnutzung und niedrigerem Stromverbrauch (in der Gruppe der Einfamilienhäuser) positive, wenn auch geringere, Kapitalwertsteigerungen aufweisen.

Insgesamt verdeutlichen die Ergebnisse, dass die Integration von E-Pkw in bestehende PV-Systeme den Eigenverbrauch erhöht, Stromkosten senkt und die Wirtschaftlichkeit des Gesamtsystems langfristig verbessert. Insbesondere steigende Strompreise und sinkende Technologiekosten verstärken diesen Effekt und machen die Investition in PV und E-Pkw langfristig attraktiver als die reine PV-Installation.

## 8.7 Ergebnisse Modellkopplung PGEP-AMIRIS (DLR & IOR)

Ziel der Modellkopplung zwischen AMIRIS und PGEP ist es, die unsichere Entwicklung des Kraftwerkparcs mit den tatsächlichen Entscheidungen auf dem Markt abzugleichen. Durch das iterierte Feedback der Modelle erhalten wir robuste Szenarienpfade.

Um unsere Simulations-Optimierungsmodelle zu testen, lösen wir zuerst das PGEP-Problem ohne Berücksichtigung von AMIRIS, d.h., das reine Optimierungsmodell dient als Benchmark für unsere drei Simulations-Optimierungsmodelle. Der Doppelzerlegungsalgorithmus wird zur Lösung des generierten Modells verwendet. Um die Rechenleistung zu verbessern, nehmen wir den Gesamtleistungsbedarf als gültige Ungleichung in das Hauptproblem des Doppelzerlegungsalgorithmus auf.

Abbildung 31 zeigt die Ergebnisse der Doppelzerlegungsalgorithmus für das PGEP-Problem ohne AMIRIS. Es dauert 7 Iterationen, bis der Ansatz der Algorithmus konvergiert. Abbildung 31 (a) zeigt die Konvergenz der (approximativen) oberen und (validen) unteren Schranken. Die oberen Schranken stellen die entsprechenden Gesamtsystemkosten für die jeweilige Lösung des Doppelzerlegungsalgorithmus pro Iteration dar. Die jährliche Gesamterzeugungskapazität ist für jede Technologie in Abbildung 31 (b) separat dargestellt. Während die Wind- und Erdgastechnologie ihre Kapazität um 87 % bzw. 15 % erhöht hat, wurde die Öltechnologie vollständig stillgelegt.

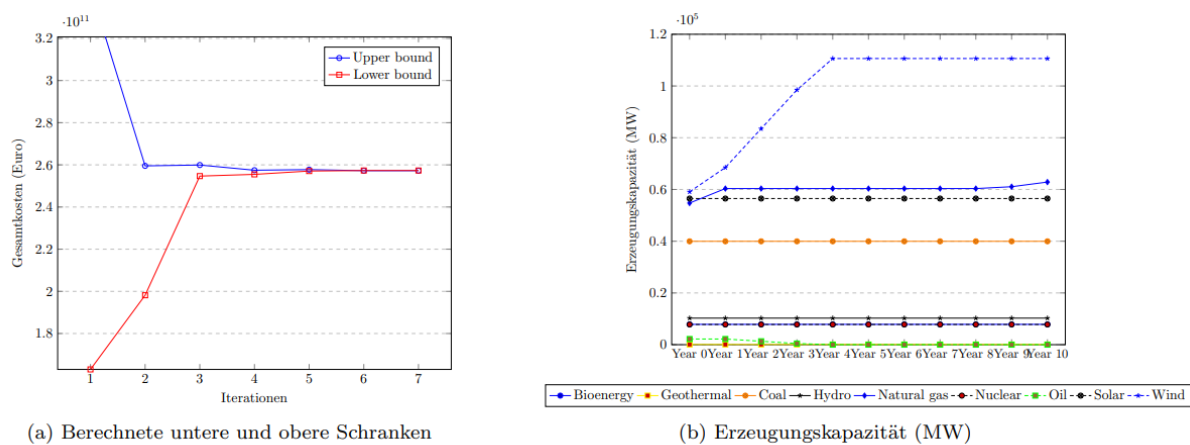
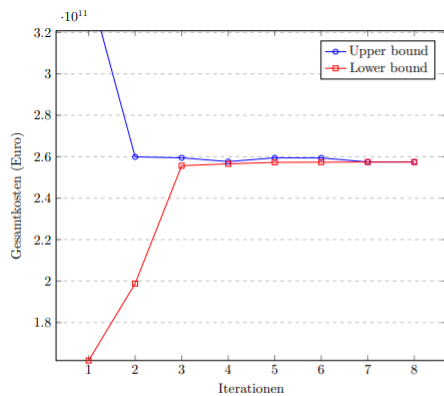
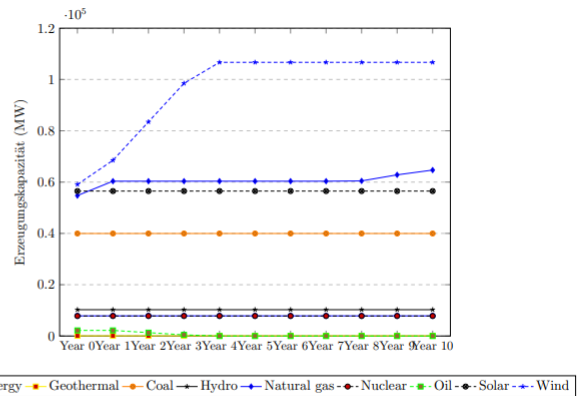


Abbildung 31. Lösungen für das PGEP

Neben dem PGEP-Problem ohne AMIRIS, betrachten wir in der 1. Kopplungsstrategie ein Modell, bei dem ein agentenbasierter Simulationsansatz verwendet wird, ohne das Optimierungs-Unterproblem. Zusätzlich zu diesen beiden Modellen verwenden die beiden Kopplungsstrategien 2 und 3 sowohl stochastische Optimierung als auch agentenbasierte Simulation. Die Ergebnisse der drei Kopplungsstrategien sind in den folgenden Abbildungen 32, 33, und 34 für jede Strategie einzeln dargestellt. Diese Abbildungen zeigen jeweils die Konvergenz der beiden Modelle (AMIRIS und SOM) bei den Gesamtsystemkosten und die Portfolioentscheidungen bezüglich der zugebauten Technologien.




(a) Berechnete untere und obere Schranken



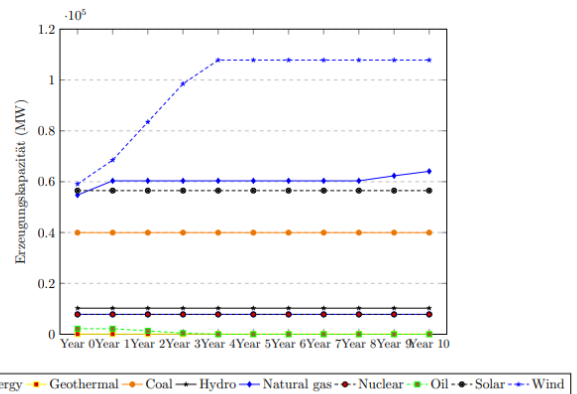
(b) Erzeugungskapazität (MW)

Abbildung 32. Lösungen für die Kopplungsstrategie 1 zwischen AMIRIS und PGEP

Der Vergleich der Gesamtsystemkosten der vier Modelle ist naheliegend, aber doch höchst problematisch. Dies liegt daran, dass die vier Modelle jeweils unterschiedliche Zielfunktionen optimieren. Daher sind gewisse Abweichungen zu erwarten, selbst wenn alle Modelle dieselbe Lösung berechnen würden. Wir erstellen weiter unten einen „out-of-sample“ Test um die Gesamtkosten der berechneten Lösungen der verschiedenen Modelle miteinander vergleichen zu können.




(a) Berechnete untere und obere Schranken




(b) Erzeugungskapazität (MW)

Abbildung 33. Lösungen für die Kopplungsstrategie 2 zwischen AMIRIS und PGEP

Entscheidungen zum Energieportfolio folgen bei allen Strategien einem ähnlichen Muster: Öltechnologie wird ausgemustert, während bei Wind- und Erdgastechnologien die Kapazitäten erhöht werden. Insbesondere kommt es zu Kapazitätssteigerungen von 81-87 % bei Wind- und 15-18 % bei Erdgastechnologien. Für Kopplungsstrategie 1 zeigt Abbildung 32 (b), dass die Öltechnologie vollständig stillgelegt wird, während Erdgas- und Windtechnologien die Kapazität um 18 % bzw. 81 % erhöhen. Kopplungsstrategie 2 beinhaltet die Stilllegung der Öltechnologie sowie Kapazitätserweiterungen von 17 % für Erdgastechnologien und 82 % für Windtechnologien (siehe Abbildung 33 (b)). Abbildung 33 (b) zeigt, dass die Kopplungsstrategie 3 eine Kapazitätserweiterung von 84 % bei der Windkraft und von 16 % bei der Erdgastechnologie bietet. Andererseits führt der Ansatz der Doppelzerlegungsalgorithmus zu einer größeren Investition in die Windtechnologie (87 %) und einer geringeren Investition in Erdgas (15 %). Insgesamt erreicht die Gesamtkapazität des Energieportfolios im 10. Jahr etwa 293-295 GW.



(a) Berechnete untere und obere Schranken



(b) Erzeugungskapazität (MW)

Abbildung 34. Lösungen für die Kopplungsstrategie 3 zwischen AMIRIS und PGEP

In unserem Fall konzentrieren wir uns auf die Anzahl der Iterationen im Benders-Algorithmus, um deren Rechenleistung zu verstehen. In diesem Zusammenhang untersuchen wir die Anzahl der Iterationen in allen Strategien, um Konvergenz zu erreichen. Der Doppelzerlegungsalgorithmus alleine ohne AMIRIS benötigt 7 Iterationen, während die Kopplungsstrategie 1 nach 8 Iterationen abschließt. Die Kopplungsstrategie 2 benötigt aufgrund ihrer sequentiellen Ausführung 10 Iterationen. Die Kopplungsstrategie 3 ist leistungsfähiger als die anderen Strategien und erreicht eine Konvergenz in 6 Iterationen. Kopplungsstrategie 3 benötigt die geringste Rechenzeit.

Um die Sensitivität der berechneten Lösungen bzw. deren Einfluss auf die Gesamtkosten zu testen, lösen wir alle Modelle zehn Mal. Jeder Rechendurchlauf verwendet hierbei andere Stichproben des Szenariobaums. Dies führt zu unterschiedlichen Portfolioentscheidungen. Ein Boxplot der resultierenden Gesamtkosten ist in Abbildung 35 (a) dargestellt. Hierbei ist DD der Doppelzerlegungsalgorithmus für das PGEP-Problem ohne AMIRIS. Die drei Kopplungsstrategien sind mit CP1, CP2 und CP3 abgekürzt. Da die Zielfunktionen der Modelle unterschiedlich sind (siehe oben), können die Gesamtkosten nicht verglichen werden. Stattdessen veranschaulichen die Boxplots die Bandbreite der möglichen Ergebnisse. Wir stellen fest, dass die Kopplungsstrategie 3 die geringste Abweichung unter den vier Strategien aufweist.

Anschließend verwenden wir Out-of-Sample-Tests, um die Stromportfolioentscheidungen der vier Modelle zu bewerten. Wir untersuchen die Lösung und damit die resultierenden Gesamtkosten jeder Strategie, indem wir ihre Stromportfolioentscheidungen sowohl im AMIRIS als auch im stochastischen Rahmen als Out-of-Sample-Test bewerten. Wir wählen zufällig eine Lösung für den Out-of-Sample-Test aus. Die Stromportfolio-Entscheidungen jedes Modells werden für diese Bewertung festgelegt, und ihre Betriebsphasen werden dann unabhängig voneinander in SDDP und AMIRIS gelöst. Es werden insgesamt 500 Szenarien berücksichtigt, 250 für SDDP und 250 für AMIRIS. Die Ergebnisse für das stochastische Betriebsproblem (gelöst durch SDDP) sind in Abbildung 36(b) dargestellt, und die Ergebnisse für die beiden Modelle (SDDP und AMIRIS) sind in Abbildung 36 (c) zusammengefasst.




Abbildung 35. Sensitivitätsanalyse (a) und Out-of-Sample-Tests (b) und (c).

Dies sind unsere wichtigsten Beobachtungen: (1) Die drei Kopplungsstrategien führen zu einer statistisch signifikanten Reduzierung der Gesamtsystemkosten im Vergleich zum Optimierungsmodell allein; siehe Abbildung 35 (c). (2) Zwischen den drei Kopplungsstrategien besteht kein statistisch signifikanter Unterschied der Gesamtkosten. Allerdings führen bereits minimalen Verbesserungen zu gigantischen Kosteneinsparungen, da die Gesamtkosten sehr groß sind. (3) Die Kopplungsstrategie 3 (CP3) hat die geringste Standardabweichung.


Zusammenfassend lässt sich sagen, dass die drei Kopplungsstrategien offenbar zu besseren Portfolioentscheidungen führen als das Optimierungsmodell (DD) allein. Kopplungsstrategie 3 hat leichte Vorteile gegenüber den anderen beiden Strategien, da die berechneten Lösungen weniger sensitiv (also robuster) zu sein scheinen und gleichzeitig die Rechenzeit am geringsten ist.

In einem zusätzlichen numerischen Experiment fügen wir die Topologie des Übertragungsnetzes aus Grimm et al. (2022) in das PGEP-Modell ein und lösen es mit dem entwickelten Doppelzerlegungsalgorithmus. Abbildung 36 zeigt die betrachteten Übertragungsleitungen sowie Abbildung 37 die Konvergenz- und Jahresstromportfoliokapazitäten.


Wenn wir Übertragungsleitungen berücksichtigen, sind die Gesamtsystemkosten um 37 % höher als die Ergebnisse im Fall ohne Übertragungsleitung. Bei der Erdöltechnologie ist ein Kapazitätsrückgang von etwa 91 % zu verzeichnen, während bei der Wind-, Solar- und Erdgastechnologie Kapazitätssteigerungen von 48 %, 16 % bzw. 40 % zu verzeichnen sind.



Abbildung 36. Fall mit Übertragungsleitungen



(a) Berechnete untere und obere Schranken



(b) Erzeugungskapazität (MW)

Abbildung 37. Ergebnisse für den Fall mit Übertragungsleitungen

## 9 Zusammenfassung

Das Projekt hat die politischen, gesellschaftlichen und ökonomischen Unsicherheiten in zukünftigen Energiesystemen quantifiziert, insbesondere die Kraftwerkportfolien durch stochastische Programmierung, die Diffusion von E-Pkw, PVS und Wärmepumpen in privaten Haushalten, und deren Betriebsstrategien. Die so bestimmten Transformationspfade berücksichtigen nicht nur die externen Unsicherheiten des Energiesystems, sondern auch die Unsicherheiten und Risiken beteiligter Akteure und deren daraus resultierenden Handlungsstrategien und deren Wechselwirkung miteinander.

Um diese Ziele erreichen zu können wurden in diesem Projekt mehrere methodische Weiterentwicklungen durchgeführt.

Erstens wurde ein Diffusionsmodell bis 2045 für die zukünftige Entwicklung von PV und E-Pkw entwickelt. Bei der Betrachtung der Investitionen von Haushalten in PV und/oder E-Pkw zeigt sich klar, dass die Kombination aus beiden Technologien langfristig viel attraktiver als die reine PV-Installation



ist. Verknüpft man die optimalen Speichersystemgrößen mit den prognostizierten Diffusionszahlen, ergibt sich ab dem Jahr 2024 bis einschließlich 2045 eine kumulierte Gesamtkapazität der PV-Neuinstallationen bei den betrachteten Gebäuden im Haushaltssektor von 105,3 GW sowie 70,6 GWh kumulierte Speicherkapazität.

Zweitens wurde unseres Wissens nach erstmalig ein stochastisches Optimierungsmodell mit einer agentenbasierten Simulation gekoppelt. Diese Kopplung erlaubt es im Detail, die vielfachen Unsicherheiten – von der Zusammensetzung des Kraftwerkparcs bis hin zu den Geschäftsentscheidungen der wichtigen Akteure am Elektrizitätsmarkt – in einer ständigen Feedbackschleife zu quantifizieren. Dies geschieht innerhalb der bekannten ARIADNE-Szenarien. Alle drei Kopplungsstrategien reduzieren die Gesamtsystemkosten statistisch signifikant im Vergleich zum Optimierungsmodell – was die Methodik im Nachhinein rechtfertigt. In vielen Szenarien zeigen sich ähnliche Muster: Öltechnologie wird ausgemustert, während die Kapazitäten von Wind- (81-87%) und Erdgastechnologien (15-18%) erhöht werden, je nach Kopplung und Szenario. Insgesamt erreicht die Gesamtkapazität des Energieportfolios im 10. Jahr etwa 293-295 GW.

Drittens konnten die jeweils optimierten E-Pkw, PVS und Wärmepumpen-Modelle, also individuelle Entscheidungen auf Haushalts-Ebene, erfolgreich in ihrer Aggregation für den Gesamtverbrauch in Deutschland durch ML-Modelle abgebildet werden. So liegt z. B. der mittlere absolute Fehler (MAE) bei ~ 680 MWh für das PVS-Modell. Bei einer Spanne zwischen -22 949 MWh und +11 126 MWh ist das ein gutes Ergebnis. Die Einspeisung und Stromentnahme von PVS-Haushalten kann also insgesamt gut durch ML abgebildet werden.

Das hat eine hohe Bedeutung für weitere Projekte, da jetzt im Prinzip *jedes* durch ein ML oder anderes statistisches Modell abbildbare individuelle Verhalten in einem nationalen Strommarktmodell eingebunden werden kann, ohne die Laufzeit signifikant zu beeinträchtigen. Damit ist die Brücke zwischen psychologischen Einzelentscheidungen und nationalen Kennzahlen geschlagen.

Viertens wurde für drei Flexibilitäten – Wärmepumpen, E-Pkw und PVS – die Integration in AMIRIS erreicht. Sie sind jetzt in der Lage, auf Strompreissignale zu reagieren. Haushaltstypen können in ihren Mustern unterschieden und in ihrer Reaktion auf Preissignale abgebildet werden. Skaliert man diese Betriebslogiken hoch und simuliert diese Akteure in AMIRIS, so ergeben sich z. B. für Wärmepumpen, dass voraussichtlich bis 2040 die Einführung von Real-Time-Pricing bei flexiblem Wärmepumpen-Betrieb die maximale Residuallast um ca. 3 bis 5 GW bis 2040 (ca. 3%) reduzieren kann. Für die Verbraucher bringt nach diesen Analysen der kostenminimierende Wärmepumpenbetrieb mit RTP jährliche Bruttostromkosteneinsparungen von 6 % bis 27 %, je nach Gebäudetyp. Maximal werden sogar bis zu 74 % Einsparungen erreicht, nämlich dann, wenn der Eigenverbrauch von PV verstärkt wird, eine hohe Komforttoleranz gegeben ist, und gut isolierte Gebäude mit hoher thermischer Trägheit vorliegen.

Die Abbildung massiver Unsicherheiten im Kraftwerksausbau und von Ein- und Ausspeicherentscheidungen dreier Technologien in ihrer gegenseitigen Abhängigkeit ist durch diese methodischen Weiterentwicklungen gelungen und hat die oben genannten Ergebnisse erbracht, die von Relevanz für zukünftige regulatorische Entscheidungen sind.

## 10 Schlussfolgerungen

Die Quantifizierung von miteinander verbundenen Unsicherheiten wie die Investitionsentscheidungen von Haushalten bezüglich PVS, E-Pkw und Wärmepumpen, sowie der Zubau neuer Kraftwerke

erforderte neue Methodenentwicklungen und Modellkopplungen. Die erfolgte Modellkoppelung zwischen einem SOM und einem ABM hat sich als ein wichtiges Werkzeug herausgestellt, um die Vorteile dieser beiden Modellierungsansätze miteinander zu kombinieren. Nur so können zukünftige Energiesysteme in ihrer Komplexität und ihren verbundenen Unsicherheiten und Entwicklungspfaden verstanden werden, und nur so kann das Gesamtsystem Energie in all seinen Aspekten ohne blinde Flecken ausgeleuchtet werden.

Daraus ergibt sich unsere erste Schlussfolgerung: *Modellkopplungen sind zwar technisch extrem anspruchsvoll zu implementieren, haben sich aber – hier und auch in anderen Projekten – als sehr fruchtbar erwiesen. Deshalb spricht vieles dafür, Modellkopplungen als Standard zu etablieren.*

In En4U ging es auch darum, die Entscheidungen und Marktentwicklungen zentraler Akteure genauer zu verstehen. Durch die Anbindung externer ML-Modelle an AMIRIS zur Laufzeit ist dies geschehen. Diese Kopplung hat sich demnach als sehr wichtig erwiesen – und zwar prinzipiell zwischen eigenständigen Modellen des maschinellen Lernens und einem bereits existierenden „Hauptmodell“ AMIRIS. Diese Möglichkeit, ML-Funktionalität in ihrer ganzen Breite und Vielfalt in AMIRIS (aber auch jedem anderen Modell) nutzen zu können, ist methodisch für zukünftige Modellentwicklung sehr wichtig, weil dadurch eine große Flexibilität gewonnen wird. In diesem Sinne kann z. B. eine agentenbasierte Simulation den Schirm über vielen anderen, völlig verschiedenen Modellierungen bilden, die jeweils für die Entscheidungslogik einer Gruppe von Agenten zuständig ist. Jede Gruppe kann einer völlig anderen Logik folgen.

Unsere zweite Schlussfolgerung lautet deshalb: *Dafür geeignete Modelle in der Energiesystemanalyse sollten so schnell wie möglich mit entsprechenden ML-Schnittstellen ausgerüstet werden, um diese Funktionalität für sich nutzbar zu machen.*

## 11 Verwendung der Zuwendung

### 11.1 Bezug zu förderpolitischen Zielen

Die Forschungsförderungsbekanntmachung zum 7. Energieforschungsprogramm der Bundesregierung nennt die Systemanalyse als einen Schwerpunkt der wissenschaftlichen Arbeit zur Unterstützung der Energiesystemtransformation in Deutschland. Zur Gewinnung eines besseren Verständnisses des Beitrags verschiedener Technologien zu Energiewende wird dabei nicht nur die inhaltliche, sondern auch die methodische Weiterentwicklung von Energiesystemmodellen hervorgehoben. Dazu leistete das Projekt EN4U mit seinen Ergebnissen einen fundamentalen Beitrag, da es innovative informationstechnische Verfahren weiterentwickelt, und für die Energiesystemmodellierung erschlossen hat. Durch die erreichte Beschleunigung konnte die Analysefähigkeit der beteiligten Modelle, und insbesondere des AMIRIS-Modells, deutlich gesteigert werden. Insbesondere die erstmalige harte Kopplung eines stochastischen Optimierungsmodells und die Einbindung von ML-basierten externen Modellen als Agenten sind hier hervorzuheben. Damit einher geht eine wesentliche Stärkung der modellgestützte Energiesystemanalyse in ihren Möglichkeiten, den politischen Entscheidungsträgern wichtiges Orientierungswissen zur Ausgestaltung der Energiewende bereitzustellen

### 11.2 Erfolgte und geplante Veröffentlichung der Ergebnisse

Die folgende Tabelle fasst die *Vorträge, Poster und Publikationen* zusammen, die aus dem Projekt entstanden sind.

Tabelle 10. Übersicht aller Publikationstätigkeiten

| Typ                       | Autoren                          | Titel  | Journal / Konferenz                                   | Status        |
|---------------------------|----------------------------------|--|---|---------------|
| Konferenzbeitrag (Poster) | Fabia Miorelli et al. (2022)     | Electric vehicles smart charging: Representative load profiles based on residential time-varying electricity tariffs and household characteristics | IAEE European Energy Conference, Athens               | Abgeschlossen |
| Konferenzbeitrag          | A. Achraf El Ghazi et al. (2024) | Enhancing Household-Level Operational Decision Making with Machine Learning  | EURO, Kopenhagen                                      | Abgeschlossen |
| Konferenzbeitrag          | Ulrich Frey et al. (2024)        | Capturing uncertainties of household decision making with machine learning in an agent-based model   | ABM4Energy, Freiburg                                  | Abgeschlossen |
| Konferenzbeitrag          | Ulrich Frey et al. (2023)        | Modelling actors' behavior in a decentralized energy system with machine learning  | GOR-Konferenz, Zürich                                 | Abgeschlossen |
| Konferenzbeitrag          | Ulrich Frey et al. (2023)        | Forecasting multiple attributes considering uncertainties in a coupled energy systems model  | CFE-CMStatistics, Berlin                              | Abgeschlossen |
| Konferenzbeitrag          | Evelyn Sperber et al. (2023)     | Uncertainties and interactions in various transition pathways of a decentralized energy system   | INREC, Essen  | Abgeschlossen |
| Konferenzbeitrag (Poster) | Ulrich Frey et al. (2022)        | En4U – Pathways of a decentralised energy system under uncertainty   | Treffen des Forschungsnetzwerks Systemanalyse, Berlin | Abgeschlossen |
| Konferenzbeitrag          | Kaya et al. (2023)               | Integrated stochastic model with electricity market simulation for long-term   | INFORMS, Phoenix                                      | Abgeschlossen |

|                       |   | generaton<br>planning  | expansion                             |  |  |
|-----------------------|---|--|---------------------------------------|--|--|
| Konferenz-<br>beitrag | Kaya et al. (2022)  | A long-term expansion considering quotas under uncertainties   | generation planning emission multiple | INFORMS, Indianapolis  | Abgeschlossen                                    |
| Konferenz-<br>beitrag | Kaya et al. (2022)  | A long-term expansion considering quotas under uncertainties   | generation planning emission multiple | OR2022, Karlsruhe  | Abgeschlossen                                    |
| Konferenz-<br>beitrag | Stephanie Stumpf et al. (2023)  | Determinants of residential photovoltaic and battery storage adoption in Germany   |                                       | Enerday 2023, Dresden  | Abgeschlossen                                    |
| Konferenz-<br>beitrag | Stephanie Stumpf et al. (2023)  | Analysing differences in household's renewable technology profiles: A comparison of socio-psychological characteristics            |                                       | IAEE 2023, Mailand   | Abgeschlossen                                    |
| Konferenz-<br>beitrag | Stephanie Stumpf et al. (2023)  | Adoption of residential photovoltaic and battery storage adoption in Germany: A comparison between adopters and non-adopters       |                                       | Behave 2023 (7th European Conference on Behaviour and Energy Efficiency), Maastricht | Abgeschlossen                                    |
| Artikel               | Kaya, Anil,<br>El Ghazi, Achraf,<br>Frey, Ulrich,<br>Rebennack,<br>Steffen (2025) | Coupling Stochastic Optimization with Agent-Based Simulation: A Framework for Efficient Power Expansion Planning under Uncertainty |                                       |  | Im Review (Production and Operations Management) |
| Artikel               | Frey, Ulrich,<br>El-Ghazi, Achraf,<br>Miorelli, Fabia                             | Bridging the gap – connecting energy system models and individual decision-making  |                                       |  | In Vorbereitung (PlosOne)                        |

|                           |   |   |   |  |
|---------------------------|---|---|---|--|
| Artikel                   | Miorelli, Fabia, Wulff, Niklas, Fuchs, Benjamin, Gils, Hans Christian, Jochem, Patrick (2025) | An open-source Python-based model to represent the charging flexibility and vehicle-to-grid potential of electric vehicles in energy systems models: venco.py |   | Im Review (JOSS), Preprint vorhanden               |
| Artikel/<br>Working paper | Fett et al. (2023)  | Provision of frequency containment reserve from residential battery storage systems: A German case study  | Working Paper Series in Production and Energy No. 71, June 2023 | Abgeschlossen                                      |
| Artikel                   | Stephanie Stumpf et al. (2025)  | Integrating Residential PV and Battery Storage Adoption: A Structural Comparison of Decision-Making Processes   |   | In Vorbereitung (Energy Research & Social Science) |

---

## 12 Abbildungsverzeichnis

|  |    |
|--|----|
| Abbildung 1. Aufbau des Projekts En4U und Modellkopplung .....   | 11 |
| Abbildung 2. Modellstruktur AMIRIS.....  | 13 |
| Abbildung 3. Aggregation der einzelnen Haushaltsentscheidungen durch maschinelles Lernen zur Vorhersage der Gesamtbelastung.....           | 17 |
| Abbildung 4. Struktur des Modells venco.py (Miorelli et al. 2024 preprint). ....   | 25 |
| Abbildung 5. Aufbau des LSTM-Modells .....   | 31 |
| Abbildung 6. Der Doppelzerlegungsalgorithmus .....   | 40 |
| Abbildung 7. Das PGEP-Problem als Simulation-Optimierungsmodell und dem integrierten Doppelzerlegungsalgorithmus.....                      | 42 |
| Abbildung 8. Kopplungsstrategie 1 zwischen AMIRIS und SOM .....  | 43 |
| Abbildung 9. Kopplungsstrategie 2 zwischen AMIRIS und SOM .....  | 44 |
| Abbildung 10. Kopplungsstrategie 3 zwischen AMIRIS und SOM .....   | 45 |
| Abbildung 11. RCE-basierter Workflow der gekoppelten Modelle .....   | 48 |
| Abbildung 12. CO <sub>2</sub> -Preise nach Szenario nach WEO.....  | 51 |
| Abbildung 13. Vergleich der Systemkosten zwischen Referenzszenario und stochastisch optimiertem Szenario .....                             | 53 |
| Abbildung 14. Differenz der Systemkosten zwischen ARIADNE Szenario und ARIADNE Szenario plus PVS und E-Pkw Agenten .....                   | 54 |
| Abbildung 15. Vergleich der Verteilung der Ertragspotentiale der vier Referenz-Wetterstandorte....   | 55 |
| Abbildung 16. Verteilung des Ertragspotentials in Würzburg über das Jahr .....   | 55 |
| Abbildung 17. Optimierte individuelle Netzeinspeisung der Haushaltstypen MH2, MH9 und MH10 in Würzburg (2021) .....                        | 56 |
| Abbildung 18. Aggregierte Netzeinspeisung aller deutschen PVS-ausgestatteten Haushalte basierend auf Wetterdaten von Würzburg (2021) ..... | 56 |
| Abbildung 19. Exemplarischer Wärmepumpeneinsatz gemäß dem Mikromodell Wärmepumpen.....   | 58 |
| Abbildung 20. Jahresstromverbrauch von Luft/Wasser-Wärmepumpen für verschiedene Gebäudetypen und Nutzertoleranzen .....                    | 58 |
| Abbildung 21. Jährliche Stromkosten von Luft/Wasser-Wärmepumpen für verschiedene Gebäudetypen und Nutzertoleranzen .....                   | 59 |
| Abbildung 22. Aggregierter Stromverbrauch von Wärmepumpen im Szenario 2040 (Wetterjahr 2019) .....   | 59 |
| Abbildung 23. Beispielhaftes Ergebnis für flexibles preisbasiertes Laden für Cluster 2. ....   | 61 |
| Abbildung 24. Beispielhaftes Ergebnis für flexibles preisbasiertes Laden für Cluster 14. ....  | 62 |
| Abbildung 25. Training mit 4-facher Cross-validation.....  | 63 |
| Abbildung 26. Tatsächliche Einspeisung+Entnahme PVS vs. vorhergesagte Werte .....  | 64 |

|   |    |
|---|----|
| Abbildung 27. Fehlerverteilung nach prozentualer Abweichung.....                  | 64 |
| Abbildung 28. Art der Fehlerverteilung.....                                       | 65 |
| Abbildung 29. Diffusionsverläufe der E-PV für drei untersuchte Szenarien .....    | 66 |
| Abbildung 30. Diffusionsverläufe der E-Pkw für vier untersuchte Szenarien .....   | 67 |
| Abbildung 31. Lösungen für das PGEP.....  | 68 |
| Abbildung 32. Lösungen für die Kopplungsstrategie 1 zwischen AMIRIS und PGEP..... | 69 |
| Abbildung 33. Lösungen für die Kopplungsstrategie 2 zwischen AMIRIS und PGEP..... | 69 |
| Abbildung 34. Lösungen für die Kopplungsstrategie 3 zwischen AMIRIS und PGEP..... | 70 |
| Abbildung 35. Sensitivitätsanalyse (a) und Out-of-Sample-Tests (b) und (c).....   | 71 |
| Abbildung 36. Fall mit Übertragungsleitungen .....                                | 72 |
| Abbildung 37. Ergebnisse für den Fall mit Übertragungsleitungen .....             | 72 |

## 13 Tabellenverzeichnis

|  |    |
|--|----|
| Tabelle 1. Übergabe-Variablen zwischen den ML-Modellen (E-Pkw und PVS) und AMIRIS .....  | 15 |
| Tabelle 2. Mapping von MiD-Variablen zu Haushaltscluster-Merkmalen im En4U-Projekt. .... | 22 |
| Tabelle 3. Zusammenfassung der Merkmale von Haushaltsclustern mit Elektrofahrzeugen..... | 24 |
| Tabelle 4. Übersicht der Modellparameter von venco.py .....                              | 25 |
| Tabelle 5. Eingabeparameter für die Optimierung .....                                    | 27 |
| Tabelle 6. Input und Output-Variablen für das E-Pkw-Modell.....                          | 32 |
| Tabelle 7. Input und Output-Variablen für das PVS-Modell.....                            | 32 |
| Tabelle 8. Input und Output-Variablen für das Wärmepumpen-Modell .....                   | 33 |
| Tabelle 9. Fehler pro Modell .....   | 63 |
| Tabelle 10. Übersicht aller Publikationstätigkeiten .....                                | 75 |

## 14 Abkürzungsverzeichnis

**AMIRIS** = Agent-based Market model for the Investigation of Renewable and Integrated energy Systems

**CHP** = Combined heat and power

**HighFlex** = Flexible Wärmepumpen-Betriebsweise mit hoher Nutzertoleranz

**Inflex** = Inflexible Wärmepumpen-Betriebsweise

**LCA** = Latent Class Analysis

**ML** = Maschinelles Lernen

**ModFlex** = Flexible Wärmepumpen-Betriebsweise mit moderater Nutzertoleranz

**NN** = Neuronale Netze

**NLS** = Nonlinear Least Squares

**PVS** = Photovoltaik und Speicher

**RTP** = real-time pricing

**RCE** = Remote Component Environment

**SOM** = stochastisches Optimierungsmodell



## 15 Literaturverzeichnis

- Agora Energiewende, Prognos, Consentec (2022): Klimaneutrales Stromsystem 2035. Wie der deutsche Stromsektor bis zum Jahr 2035 klimaneutral werden kann. Online verfügbar unter [https://www.agora-energiewende.de/fileadmin/Projekte/2021/2021\\_11\\_DE\\_KNStrom2035/A-EW\\_264\\_KNStrom2035\\_WEB.pdf](https://www.agora-energiewende.de/fileadmin/Projekte/2021/2021_11_DE_KNStrom2035/A-EW_264_KNStrom2035_WEB.pdf), zuletzt geprüft am 26.11.2024.
- Anderson, Kevin S.; Hansen, Clifford W.; Holmgren, William F.; Jensen, Adam R.; Mikofski, Mark A.; Driesse, Anton (2023): pvlb python: 2023 project update. In: *JOSS* 8 (92), S. 5994. DOI: 10.21105/joss.05994.
- Bakher Naseri, Mohammad; Elliott, Greg (2013): The diffusion of online shopping in Australia: Comparing the Bass, Logistic and Gompertz growth models. In: *J Market Anal* 1 (1), S. 49–60. DOI: 10.1057/jma.2013.2.
- Bass, Frank M. (1969): A New Product Growth for Model Consumer Durables. In: *Management Science* 15 (5), S. 215–227. DOI: 10.1287/mnsc.15.5.215.
- Bauer, Johannes (2022): A Primer to Latent Profile and Latent Class Analysis. In: Michael Goller, Eva Kyndt, Susanna Paloniemi und Crina Damşa (Hg.): *Methods for Researching Professional Learning and Development*, Bd. 33. Cham: Springer International Publishing (Professional and Practice-based Learning), S. 243–268.
- Benassi, Mariagrazia; Garofalo, Sara; Ambrosini, Federica; Sant’Angelo, Rosa Patrizia; Raggini, Roberta; Paoli, Giovanni de et al. (2020): Using Two-Step Cluster Analysis and Latent Class Cluster Analysis to Classify the Cognitive Heterogeneity of Cross-Diagnostic Psychiatric Inpatients. In: *Frontiers in psychology* 11, S. 1085. DOI: 10.3389/fpsyg.2020.01085.
- Birge, John R. (1985): Decomposition and partitioning methods for multistage stochastic linear programs. In: *Operations Research* 33 (5), S. 989–1007.
- Brusco, Michael J.; Shireman, Emilie; Steinley, Douglas (2017): A comparison of latent class, K-means, and K-median methods for clustering dichotomous data. In: *Psychological methods* 22 (3), S. 563–580. DOI: 10.1037/met0000095.
- C3S (2018): ERA5 hourly data on single levels from 1940 to present.
- Deissenroth, Marc; Klein, Martin; Nienhaus, Kristina; Reeg, Matthias (2017): Assessing the Plurality of Actors and Policy Interactions: Agent-Based Modelling of Renewable Energy Market Integration. In: *Complexity* 2017, S. 1–24. DOI: 10.1155/2017/7494313.
- Eggs, Johannes; Follmer, Robert; Gruschwitz, Dana; Nobis, Claudia; Bäumer, Marcus; Pfeiffer, Manfred (2018): *Mobilität in Deutschland – MiD Methodenbericht*. Studie von infas, DLR, IVT und infas 360 im Auftrag des Bundesministers für Verkehr und digitale Infrastruktur. infas, DLR, IVT und infas 36. Bonn, Berlin. Online verfügbar unter [www.mobilitaet-in-deutschland.de](http://www.mobilitaet-in-deutschland.de), zuletzt geprüft am 30.01.2025.
- Fett, Daniel; Fraunholz, Christoph; Keles, Dogan (2021): Diffusion and system impact of residential battery storage under different regulatory settings. In: *Energy Policy* 158, S. 112543. DOI: 10.1016/j.enpol.2021.112543.
- Grimm, Veronika; Sölch, Christian; Zöttl, Gregor (2022): Emissions reduction in a second-best world: On the long-term effects of overlapping regulations. In: *Energy Economics* 109, S. 105829. DOI: 10.1016/j.eneco.2022.105829.

- Hagenaars, Jacques A.; McCutcheon, Allan L. (Hg.) (2009): Applied Latent Class Analysis: Cambridge University Press.
- Hersbach, H; Bell, B; Berrisford, P; Biavati, G; Horányi, A; Muñoz Sabater, J; et al. (2024): ERA5 hourly data on single levels from 1940 to present: Copernicus Climate Change Service (C3S) Climate Data Store (CDS). Online verfügbar unter <https://cds.climate.copernicus.eu/datasets/reanalysis-era5-single-levels?tab=overview>.
- International Energy Agency (IEA) (2023): World Energy Outlook 2023: IEA. Online verfügbar unter <https://www.iea.org/reports/world-energy-outlook-2023>.
- Ismail (2013): A STUDY ON NEW PRODUCT DEMAND FORECASTING BASED ON BASS DIFFUSION MODEL. In: *Journal of Mathematics and Statistics* 9 (2), S. 84–90. DOI: 10.3844/jmssp.2013.84.90.
- Jordan, U; Braas, H; Best, I; Orozaliev, J; Vajen, K (2018): DHWcalc Update 2.02: Programm zur Generierung von Trinkwarmwasser-Zapfprofilen auf statistischer Basis. Proc. Symposium Solarthermie. Bad Staffelstein.
- Kaya, Anil; El Ghazi, Aboubakr Achraf; Frey, Ulrich; Rebennack, Steffen (2024): Coupling Stochastic Optimization with Agent-Based Simulation: A Framework for Efficient Power Expansion Planning under Uncertainty. Manuscript submitted for publication. In: *Production and Operations Management*.
- Kosow, Hannah; Weimer-Jehle, Wolfgang; León, Christian D.; Minn, Fabienne (2022): Designing synergetic and sustainable policy mixes - a methodology to address conflictive environmental issues. In: *Environmental Science & Policy* 130, S. 36–46. DOI: 10.1016/j.envsci.2022.01.007.
- Li, Ying; Sui, Mengqing (2011): Literature Analysis of Innovation Diffusion. In: *TI* 02 (03), S. 155–162. DOI: 10.4236/ti.2011.23016.
- Luderer, Gunnar; Kost, Christoph; Sörgel, Dominika (2021): Deutschland auf dem Weg zur Klimaneutralität 2045 - Szenarien und Pfade im Modellvergleich. Potsdam Institute for Climate Impact Research.
- Magidson, J; Vermunt, J K (2002): Latent class models for clustering: a comparison with K-means. In: *Canadian Journal of Marketing Research* 20 (1), S. 36–43.
- Miorelli, Fabia; Wulff, Niklas; Fuchs, Benjamin; Gils, Hans Christian; Jochem, Patrick (2024 preprint): An open-source Python-based model to represent the charging flexibility and vehicle-to-grid potential of electric vehicles in energy systems models: venco.py. In: *JOSS*.
- Nitsch, Felix; Schimeczek, Christoph; Bertsch, Valentin (2024): Applying machine learning to electricity price forecasting in simulated energy market scenarios. In: *Energy Reports* 12, S. 5268–5279. DOI: 10.1016/j.egy.2024.11.013.
- Pereira, Mario V. F.; Pinto, Leontina MVG (1991): Multi-stage stochastic optimization applied to energy planning. In: *Mathematical Programming* 52 (1), S. 359–375.
- Pflugradt, Noah; Muntwyler, Urs (2017): Synthesizing residential load profiles using behavior simulation. In: *Energy Procedia* 122, S. 655–660. DOI: 10.1016/j.egypro.2017.07.365.
- Pietzcker, Robert C.; Osorio, Sebastian; Rodrigues, Renato (2021): Tightening EU ETS targets in line with the European Green Deal: Impacts on the decarbonization of the EU power sector. In: *Applied Energy* 293, S. 116914. DOI: 10.1016/j.apenergy.2021.116914.

- Ram, M; Bogdanov, D; Aghahosseini, A; Gulagi, A; Oyewo, A S; Child, M et al. (2022): Global Energy System based on 100% Renewable Energy – Power, Heat, Transport and Desalination Sectors. Lappeenranta University of Technology and Energy Watch Group. Berlin. Online verfügbar unter [https://uk.eragroup.com/wp-content/uploads/2021/09/Global\\_system\\_renewable\\_energy\\_LUT\\_2019\\_summary.pdf](https://uk.eragroup.com/wp-content/uploads/2021/09/Global_system_renewable_energy_LUT_2019_summary.pdf).
- Rebennack, Steffen (2014): Generation expansion planning under uncertainty with emissions quotas. In: *Electric Power Systems Research* 114, S. 78–85.
- Rudolph, Frederic; Koska, Thorsten; Schneider, Clemens (2017): Verkehrswende für Deutschland: Der Weg zu CO<sub>2</sub>-freier Mobilität bis 2035. Online verfügbar unter [https://epub.wupperinst.org/frontdoor/deliver/index/docId/6812/file/6812\\_Verkehrswende.pdf](https://epub.wupperinst.org/frontdoor/deliver/index/docId/6812/file/6812_Verkehrswende.pdf), zuletzt geprüft am 25.11.2024.
- Sarfarazi, Seyedfarzad; Deissenroth-Uhrig, Marc; Bertsch, Valentin (2020): Aggregation of Households in Community Energy Systems: An Analysis from Actors' and Market Perspectives. In: *Energies* 13 (19), S. 5154. DOI: 10.3390/en13195154.
- Schade, Wolfgang; Berthold, Daniel; Mader, Simon; Scherf, Christian; Wagner, Udo; Sievers, Luisa et al. (2020): Synthese und Handlungsempfehlungen zu Beschäftigungseffekten nachhaltiger Mobilität.
- Schimeczek, Christoph; Deissenroth-Uhrig, Marc; Frey, Ulrich; Fuchs, Benjamin; Ghazi, A. Achraf El; Wetzel, Manuel; Nienhaus, Kristina (2023a): FAME-Core: An open Framework for distributed Agent-based Modelling of Energy systems. In: *JOSS* 8 (84), S. 5087. DOI: 10.21105/joss.05087.
- Schimeczek, Christoph; Nienhaus, Kristina; Frey, Ulrich; Sperber, Evelyn; Sarfarazi, Seyedfarzad; Nitsch, Felix et al. (2023b): AMIRIS: Agent-based Market model for the Investigation of Renewable and Integrated energy Systems. In: *JOSS* 8 (84), S. 5041. DOI: 10.21105/joss.05041.
- Schreiber, James B.; Pekarik, Andrew J. (2014): Technical Note: Using Latent Class Analysis versus K-means or Hierarchical Clustering to Understand Museum Visitors. In: *Curator The Museum Journal* 57 (1), S. 45–59. DOI: 10.1111/cura.12050.
- Sensfuß, Frank; Lux, Benjamin; Bernath, Christiane; Kiefer, Christoph P.; Pfluger, Benjamin; Kleinschmitt, Christoph et al. (2021): Langfristszenarien für die Transformation des Energiesystems in Deutschland 3: Kurzbericht: 3 Hauptszenarien. Online verfügbar unter <https://langfristszenarien.de/enertile-explorer-de/>, zuletzt geprüft am 26.11.2024.
- Sinha, Pratik; Calfee, Carolyn S.; Delucchi, Kevin L. (2021): Practitioner's Guide to Latent Class Analysis: Methodological Considerations and Common Pitfalls. In: *Critical care medicine* 49 (1), e63–e79. DOI: 10.1097/CCM.0000000000004710.
- Sperber, Evelyn; Frey, Ulrich; Bertsch, Valentin (2020): Reduced-order models for assessing demand response with heat pumps – Insights from the German energy system. In: *Energy and Buildings* 223, S. 110144. DOI: 10.1016/j.enbuild.2020.110144.
- Sperber, Evelyn; Schimeczek, Christoph; Frey, Ulrich J.; Cao, Karl-Kiên; Bertsch, Valentin (2024): Aligning heat pump operation with market signals: a win-win scenario for the electricity market and its actors? In: *Energy Reports*.
- Vermunt, Jeroen K.; Magidson, Jay (2009): Latent Class Cluster Analysis. In: Jacques A. Hagenaars und Allan L. McCutcheon (Hg.): *Applied Latent Class Analysis*: Cambridge University Press, S. 89–106.

Weimer-Jehle, Wolfgang (2006): Cross-impact balances: A system-theoretical approach to cross-impact analysis. In: *Technological Forecasting and Social Change* 73 (4), S. 334–361. DOI: 10.1016/j.techfore.2005.06.005.