

Energieforschungsprogramm

Publizierbarer Endbericht

Programmsteuerung:

Klima- und Energiefonds

Programmabwicklung:

Österreichische Forschungsförderungsgesellschaft mbH (FFG)

Endbericht

erstellt am

31/05/2024

Projekttitel:

Serve-U

Community-based Smart Energy Service
through flexible Optimization Models and fully
automated Data Exchange

Projektnummer:881164

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Ausschreibung	6. Ausschreibung Energieforschungsprogramm
Projektstart	01/04/2021
Projektende	29/02/2024
Gesamtprojektdauer (in Monaten)	35 Monate
ProjektnehmerIn (Institution)	FH OÖ F&E GmbH
AnsprechpartnerIn	MMag. Dr. Michael Schmidthaler
Postadresse	Wehrgrabengasse 1-3 4400 Steyr
Telefon	+43 50 804 33516
Fax	...
E-mail	Michael.Schmidthaler@fh-steyr.at
Website	...

Serve-U

Community-based Smart Energy Service through flexible Optimization Models and fully automated Data Exchange

AutorInnen:

FH OÖ:

Michael Schmidthaler

Lukas Gaisberger

Martin Eder

SCCH:

Georgios Chasparis

Energieinstitut an der JKU Linz:

Marie-Theres Holzleitner-Senck

Katrin Burgstaller

FHTW

Karthik Bhat

Andrea Werner

Blue Sky:

Wolfgang Traunmüller

Michael Backmann

OurPower:

Ulfert Höhne

Theresa Haydn

ATB Becker

Gernot Becker

Tobias Mühlberger

Sonnenplatz Großschönau

Bettina Frantes

Innsbrucker Kommunalbetriebe

Lukas Giner

Seite 3 von 115

Inhaltsverzeichnis

Inhaltsverzeichnis	4
1 Einleitung	5
1.1 Aufgabenstellung	5
1.2 Schwerpunkte des Projektes	5
1.3 Einordnung in das Programm	6
1.4 Verwendete Methoden	7
1.5 Aufbau der Arbeit:	7
2 Inhaltliche Darstellung	7
2.1 AP2: Sektorkopplung und Flexibilitätsanalyse in Energiegemeinschaften	9
2.2 AP3: Konzeption Erzeugungsprognoseplattform	9
2.3 AP4: Datengetriebene Lastprognoseplattform und Systemsicherheit	18
2.4 AP5: Smart Energy Service mit integrierter Datenqualitätsüberwachung und -verbesserung	35
2.5 AP6: Entwicklung des Systemoptimierungsmodells	45
2.6 AP7: Funktionsvalidierung / Business Case: Digitale Energiegemeinschaften	49
2.7 AP8: Netzstabilität / Regulierung / sozio-technologische Begleitforschung	54
3 Ergebnisse und Schlussfolgerungen	57
3.1 AP2: Sektorkopplung und Flexibilitätsanalyse in Energiegemeinschaften	57
3.2 AP3: Konzeption Erzeugungsprognoseplattform	58
3.3 AP4: Datengetriebene Lastprognoseplattform und Systemsicherheit	63
3.4 AP5: Smart Energy Service mit integrierter Datenqualitätsüberwachung und -verbesserung	82
3.5 AP6: Entwicklung des Systemoptimierungsmodells	84
3.6 AP7: Funktionsvalidierung / Business Case: Digitale Energiegemeinschaften	85
3.7 AP8: Netzstabilität / Regulierung / sozio-technologische Begleitforschung	99
4 Ausblick und Empfehlungen	110
5 Literaturverzeichnis	113
6 Anhang	114
7 Kontaktdaten	114

1 Einleitung

1.1 Aufgabenstellung

Im Projekt Serve-U wurde ein Energie-Service-Konzept entwickelt und validiert, welches es ermöglicht, eine Energiegemeinschaft mit minimalem technischem und finanziellem Aufwand möglichst optimal zu betreiben. In diesem Konzept wird nur bereits installierte und leicht zugängliche Sensorik verwendet, welche sich im Wesentlichen auf Smart-Meter- und Wechselrichterdaten stützt. Der Zugriff auf die Steuerung von Komponenten im Energiesystem einer Energiegemeinschaft (z.B. Wärmepumpe, Batteriespeicher, Heizpatronen und andere automatisierbare flexible Lasten) ist aufgrund der Vielzahl an unterschiedlichen, nicht genormten Schnittstellen äußerst kosten- und arbeitsintensiv. Diese Problematik wird in dem vorliegenden Projekt umgangen indem die Teilnehmer der Energie-Gemeinschaft und Nutzer des entwickelten Service selbst die Schnittstelle zu den Komponenten darstellen. In der Regel ist es dem Bewohner eines Einfamilienhauses möglich, sämtliche energierelevanten Komponenten auf verschiedene Art und Weise zu beeinflussen bzw. zu steuern. Im Projekt Serve-U wurde dieses Potential der aktiven NutzerInneneneinbindung erschlossen. Im Zuge des dargelegten Projektes wurde das wirtschaftliche und ökologische Potential eines derartigen Low-Cost-Optimierungsansatzes für Energiegemeinschaften unter Berücksichtigung nutzerInnen-spezifischer Aspekte ermittelt.

1.2 Schwerpunkte des Projektes

1.2.1 Ziel 1: Prognose & Optimierung für Energy-Communities

Als Basis für eine Optimierung der Energieflüsse wurden speziell auf Energiegemeinschaften zugeschnittene Verbrauchs- und Erzeugungsprognosen entwickelt. Diese wurden anhand historischer und aktueller Daten, sowie meteorologischer Prognosedaten erstellt und anschließend anhand statistischer Qualitätskriterien bewertet. Ein wesentliches Ziel in der Entwicklung der Prognosemethoden war die Lauffähigkeit im Echtzeitbetrieb und die kontinuierliche Aktualisierung, welche für das Energy-Service zwingend ist. Parallel dazu werden anhand historischer Daten aus der Validierungsumgebung die Flexibilitätspotentiale für eine mögliche Lastverschiebung ermittelt, mithilfe derer ein möglichst allgemeiner Optimierungsalgorithmus für Energiegemeinschaften entwickelt werden soll. Dabei ist es dem Nutzer/ der Nutzerin möglich, Flexibilitätspotentiale anzubieten und Einschränkungen zu definieren. Dieser Algorithmus unterscheidet sich durch die Berücksichtigung der nutzerrelevanten Einschränkungen wesentlich von bestehenden Ansätzen.

1.2.2 Ziel 2: Smart Energy Service mit integrierter Datenqualitätsüberwachung und -verbesserung

In einer gesicherten Datenbank laufen alle Datenströme zusammen und durchlaufen eine integrierte, auf Machine-Learning basierte Datenqualitätsüberwachung und –Verbesserung. Dadurch sind die kritischen Input-Daten für den Optimierungsalgorithmus und die Prognosen, welche ebenfalls Methoden des Machine-Learnings nutzen, optimal aufbereitet. Der Optimierungsalgorithmus erstellt anhand der Prognosen und anderen Input-Daten einen optimalen Fahrplan für die nächsten 24 Stunden für jeden Haushalt in der Energy Community. Die Plattform bietet eine NutzerInnen-Oberfläche auf der die

Energieflüsse visualisiert werden und der optimierte Fahrplan automatisiert in Handlungsempfehlungen übersetzt wird, welche der User annehmen oder ablehnen kann. Die Datenplattform erledigt somit die automatisierte Kommunikation und Abstimmung der einzelnen Community-Teilnehmer:innen aufeinander. Des Weiteren soll die Plattform

1.2.3 Ziel 3: NutzerInnen Interaktion, Anforderungen und Einschränkungen

Neben den technischen Fragestellungen unterliegt das Konzept Einschränkungen und Anforderungen hinsichtlich der NutzerInnen, des Datenschutzes und neuer legislativer Rahmenbedingungen für Energy-Communities. Um die NutzerInnen zu aktiven Handlungen zu motivieren, werden verschiedene Möglichkeiten von Anreizen untersucht. Diese können beispielsweise monetärer bzw. kompetitiver Natur sein. Mithilfe von Befragungen und Workshops wird die optimale Gestaltung der Anreize ermittelt und die optimale Frequenz der Handlungsaufforderung sowie die allgemeine Bereitschaft der Nutzer:innen zur aktiven Teilnahme untersucht. Im Projekt werden die neuen Rechtsmaterien durch die rechtliche Abteilung des Energieinstituts an der JKU Linz analysiert. Serve-U leitet daraus ab, welche Formen der Kooperation erlaubt sein werden, welche verboten bzw. welche heute erwarteten Vorteile der Energiegemeinschaften (zB Netzkostenvergünstigungen) sich tatsächlich ergeben können. Zusätzlich wird auf die relevantesten, rechtlichen, themenspezifischen Fragestellungen der Projektpartner eingegangen, um eine zielorientierte Realisierung des Projektergebnisses zu ermöglichen. Sämtliche Anforderungen und Einschränkungen werden in der Entwicklung von neuen Geschäftsmodellen berücksichtigt und können die Entwicklung der Datenplattform und des Optimierungsalgorithmus wesentlich beeinflussen.

1.2.4 Ziel 4: Zweistufiger Konzepttest in simulativer und realer Umgebung

In einem ersten Validierungsschritt des Energy-Service wird das Konzept in einer speziell für den Anwendungsfall entwickelten virtuellen, realitätsnahen Simulationsumgebung getestet. In dieser ersten Teststufe wird die Funktionalität des Energy-Service überprüft und es können bereits erste Einschätzungen hinsichtlich des Potentials des vorgestellten Konzeptes getroffen werden. Durch die zweite Testphase, in welcher das Energie Service-Konzept in verschiedenen Validierungsumgebungen laufen, wird die Anwendbarkeit des beschriebenen Energy-Service inklusive der oben genannten Teilziele geprüft werden. Aus dieser Konzept-Validierung lassen sich ableiten:

- inwiefern sich das Nutzerverhalten beeinflussen lässt
- welchen Einfluss dieser Low-Cost-Ansatz auf den Energieverbrauch und die Kosten für die gesamte Energy Community sowie jeden einzelnen Haushalt hat
- welche Einschränkungen durch die NutzerInnen gegeben sind
- welche Geschäftsmodelle sich für ein derartiges Service eignen

1.3 Einordnung in das Programm

Ziel des Projekts war die Schaffung der technischen Voraussetzungen zur breientauglichen Implementierung von Energiegemeinschaften unter Verwendung digitaler Prognose- Visualisierungs- und Optimierungsplattformen. Dies korrespondiert vorrangig in Ausschreibungsschwerpunkt 2 (Digitalisierung integrierter regionaler Energiesysteme), weist jedoch Überschneidungen im modelltheoretischen Ansatz aus AS1 (Datenerzeugung, -bereitstellung und -auswertung) auf. Die Zielsetzungen 1 und 3 (ZIEL 1:

Grand Challenges: Energieforschung im Zentrum großer gesellschaftlicher Herausforderungen und ZIEL 3: Energieforschung und Innovation als Beschäftigungsmotor für den Standort Österreich wurden projektimmanent abgedeckt.

1.4 Verwendete Methoden

Es wurden die rechtlichen und soziotechnologischen Grundlagen von Energiegemeinschaften recherchiert, analysiert und bewertet. Andererseits wurden die technischen Potentiale einer digitaler Prognose- Visualisierungs- und Optimierungsplattform durch Literaturrecherche, Simulation und Funktionsvalidierungen im Feld untersucht und bewertet. Parallel dazu wurden außerdem die wirtschaftlichen Aspekte im Zuge einer Business Case Study betrachtet.

1.5 Aufbau der Arbeit:

In der folgenden Arbeit werden die Inhalte entsprechend den Arbeitspaketen des Projektes eingeteilt.

2 Inhaltliche Darstellung

Um ein Verständnis für die Wirkungsweise der Energy Service Plattform, welche in serve-U angestrebt wurde, zu erhalten wird der grundsätzliche Prozess, welcher zum optimierten Verbrauchsverhalten in Energiegemeinschaften führen soll, im Folgenden beschrieben. Abbildung 1 gibt einen Überblick über das Konzept.




Abbildung 1: Konzeption zum Ablauf der Betriebsoptimierung durch Handlungsempfehlungen

(1) Datenerfassung:

Alle benötigten (Mess-)Daten werden von vorhandenen Geräten bezogen, somit kommt das Service-Konzept ohne jegliche Investition in zusätzliche Hardware aus. Die Geräte umfassen neben den für Energiegemeinschaften zwingend nötigen Smart-Metern (Datenübermittlung durch Netzbetreiber) auch PV-Wechselrichter und Batteriespeicher. Um optimal mit der stark variierenden Datenqualität umzugehen, werden die Datenströme einer hoch automatisierten Datenqualitätsüberwachung unterzogen. Diese vereint sowohl Expertenregeln als auch selbstlernende Analysen.

(2) Prognose:

Die analysierten und verbesserten Daten werden anschließend zur Prognose des Verbrauchs- und Erzeugungsprofils von Einzelhaushalten sowie der gesamten Community genutzt. Die Lastprognose greift dabei neben numerischen Wetterprognosen auch auf Methoden der Statistik und des maschinellen Lernens zurück. Diese Methoden kommen ebenfalls bei der Erzeugungsprognose zum Einsatz.

(3) Optimierung:

In der Optimierung laufen alle bisher erfassten und davon abgeleiteten Datenströme zusammen. Dadurch wird es möglich einen wirtschaftlich oder ökologisch optimalen Verlauf des Verbrauchsverhaltens bis zu 48 Stunden in der Zukunft zu berechnen. Bei den geltenden Tarifen und Begünstigungen in Energiegemeinschaften ist die lokale Stromnutzung am wirtschaftlichsten. Ein netzdienliches Verhalten der Gemeinschaft wird damit begünstigt. Eine Randbedingung der Optimierung ist, dass kein:e Teilnehmer:in einen wirtschaftlichen Nachteil durch den optimierten Betrieb erfahren darf. Das Ergebnis ist der optimale Leistungsverlauf der Haushalte.




Abbildung 2: Beispielhafte Prognosen mit Optimierungsbedarf (6 Haushalte)

(4) Handlungsempfehlungen:

Eine Besonderheit von Serve-U stellt die direkte Interaktion mit den NutzerInnen des Services dar. Es sollen anhand der Ergebnisse der Optimierung voll-automatisiert konkrete Handlungsempfehlungen auf Geräteebene an die Nutzer:innen weitergegeben werden. Dies stellt eine zusätzliche Unsicherheit gegenüber der direkten Ansteuerung von Gerätschaften dar. Um eine möglichst hohe Akzeptanz und Umsetzungsquote der Handlungsempfehlungen zu erreichen, werden zuerst geeignete Haushaltsgeräte analysiert und kategorisiert. Die Handlungsempfehlungen beziehen sich auf einzelne Geräte, welche bestimmten Einschränkungen (z.B. zeitlich) unterliegen. Für eine Funktionsvalidierung in mehreren Testbeds wird eine Nutzer*innen-Schnittstelle erstellt, welche die Erkenntnisse aus der sozio-technologischen Begleitforschung berücksichtigt.

(5) Handeln:

Es obliegt am Ende den Nutzer:innen ob die Handlungsempfehlungen für sie umsetzbar, zumutbar, oder interessant sind. Die Reaktionen der Teilnehmenden sind von besonderem Interesse, da daraus Möglichkeiten zur Steigerung der Umsetzungsrate abgeleitet werden. Es wird versucht verschiedene Motivatoren zur Nutzer:innen-Aktivierung zu entwickeln und deren Einsatz zu bewerten.

(6) Optimierter Verbrauch:

Letztlich ergibt sich der optimierte Haushalts- und Community-Verbrauch sowie eine Kostenersparnis gegenüber dem prognostizierten Verbrauch.

2.1 AP2: Sektorkopplung und Flexibilitätsanalyse in Energiegemeinschaften

Im Rahmen des Arbeitspakets wurden die Lastprofile von Haushalten analysiert. Die Lastprofile wurden anhand von Smart-Meter-Daten ermittelt. Darüber hinaus wurde eine Analyse der Wohnungsbelegung durchgeführt, um die Lastprofile zu klassifizieren. Für ausgewählte Gebäude wurden die Erzeugungsprofile der installierten PV-Anlagen mit Smart Metern gemessen. Das Flexibilitätspotenzial des Energiebedarfs mehrerer gängiger Haushaltsgeräte wurde ermittelt, mit einer ausgewählten Methode quantifiziert und bewertet. Das Potenzial wurde dann auf der Grundlage aktueller Statistiken auf die Länderebene hochskaliert. Es wurde eine Bewertungsmatrix mit energetischen, ökonomischen, ökologischen und nutzerbezogenen Bewertungskriterien für die Beurteilung flexibler Lasten erstellt. (M2.1). Basierend auf dieser Literaturschau wurde eine statische Potenzialabschätzung durchgeführt, in der elektrische Haushaltskomponenten mit besonders hohem/mittlerem/niedrigem Lastverschiebungs- und/oder Einsparpotenzial kategorisiert wurden. Jedes Haushaltsgerät wurde nach ökonomischen und technischen sowie sozialen Aspekten kategorisiert. Das Flexibilitätspotenzial wurde bewertet und nach sozialen und technischen Kriterien sortiert, um praktische Anwendungsfälle für die Komponenten zu identifizieren. Die Ergebnisse bilden die Grundlage für eine Auswahl von Anwendungsfällen mit optimalen technischen und finanziellen Auswirkungen.

2.2 AP3: Konzeption Erzeugungsprognoseplattform

Die wichtigsten meteorologischen Parameter für die Energieerzeugung sind die Vorhersagen der Sonnenstrahlung (Globalstrahlung) und des Windes und damit die Prognose der Stromerzeugung durch Photovoltaik und Windkraft. Dafür werden Daten der Ergebnisse von numerischen Wettervorhersagen verwendet, die weltweit zur Verfügung stehen. Mit speziellen statistischen KI-Methoden (MOS...“Model Output Statistics“) werden diese Ergebnisse weiter verbessert. Ein weiterer Ansatz sind rein datenbasierte Modelle, für die vor allem Persistenzmodelle herangezogen werden, diese besitzen aber nur teilweise meteorologische Inputs.

2.2.1 Methoden: Meteorologische Erzeugungsprognosen

Aus unterschiedlichen Datenquellen und Wettermodellen werden Temperatur- und Strahlungsprognosen für Standorte mit vorhandenen Wetterstationen bzw. statistischen Lastprognosen (z. B. Wärmepumpe, Klimaanlage, Fern- und Nahwärme) für Standorte mit detaillierter Energieverbrauchsaufzeichnung erstellt. Es werden sowohl direkte Modelldaten (DMOs) als auch nachbearbeitete (post processing) Prognosedaten verwendet. Ein Hauptaugenmerk gilt dabei der Vorhersagbarkeit von meteorologischen Phänomenen, die für den Energieverbrauch kritisch sind und örtlich (Kaltluftseen) und zeitlich (z.B. Hitzewellen, anhaltende Nebellagen) auftreten können. Die Berechnung der Heiz- und Kühllasten erfolgt mit statistischen Methoden. Der Vorhersagezeitraum der hier verwendeten Modelle liegt im Bereich von 0 – 96 Stunden.

2.2.1.1 Direkte Modelldaten (DMO... „Direct Model Output“)

Die für die Lastprognosen notwendigen meteorologischen Parameter sind Temperatur (T) und horizontale Globalstrahlung (GHI). Temperatur und Globalstrahlung sind beides Modellvariablen von numerischen Wettermodellen (NWP), die für beliebige Zeitpunkte in der Zukunft für jeden Gitterpunkt des Modells zur Verfügung stehen. Man bezeichnet diese Daten, die direkt, d.h. als Rohwert, aus dem NWP-Modell stammen als „Direct Model Output“ (DMO). Bei den NWP-Modellen unterscheidet man zwischen globalen NWP-Modellen, die für ein weltweites horizontales und vertikales Gitternetz prognostiziert werden und lokalen Wettermodellen für kleinere Gebiete wie Kontinente oder einzelne Länder.




Abbildung 1: Horizontales (links) und vertikales (rechts) Gitter eines globalen Wettermodells

Globale Wettermodelle berechnen aus einem weltweiten Anfangszustand (Messwerte zum Zeitpunkt $t=0$) mithilfe von physikalischen Gleichungen und numerischen Methoden einen Zustand der Atmosphäre in der Zukunft. Globale Wettermodelle werden von den großen nationalen Wetterdiensten betrieben und täglich 1-4 mal aktualisiert. Sie unterscheiden sich durch die geographische Genauigkeit (Gitterpunktsdistanz) und den Vorhersagezeitraum (5 bis 14 Tage). Die weltweit bedeutendsten Wettermodelle sind in Tabelle 1 dargestellt.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Tabelle 1: Beispiele von Globalen Wettermodellen

Modell	Provider	Country	Grid distance	Forecast period
GFS	NOAA	USA	22; 45; 90 km	7,5-14 days
IFS	ECMWF	(Reading, Europe)	9 km	10 days
ICON	DWD	BRD	13 km	7 days
UM	UKMO	GRB	17 km	6 days
ARPEGE	MeteoFrance	FRAU	9 km	5 days

Lokale Wettermodelle sind an die Ergebnisse und Randbedingungen von globalen Wettermodellen geknüpft und in diese eingebettet bzw. „genestet“ (siehe Abbildung 3). Lokale Modelle prognostizieren für ein kleineres Gebiet (z.B. Kontinent, Land, Bundesland) und für kürzere Vorhersagezeiträume und werden meist mehrmals täglich aktualisiert.




Abbildung 3: Verknüpfung und Einbettung („Nesting“) von lokalen Wettermodellen in globale NWP-Modelle

Lokale Wettermodelle werden mehrmals täglich (4-8 mal) aktualisiert und verfügen in der Regel über eine geringere Maschenweite (2,8 bis 7 km) und einen geringeren Vorhersagezeitraum (27 bis 72 Stunden) als globale Modelle.

Für das Projekt wurden die Daten der folgenden Wettermodelle herangezogen.

ICON_EU:

- Geographischer Ausschnitt: Europa
- Aktualisierung: 4-8 mal täglich
- Vorhersagezeitraum: 0-120 h
- Zeitliche Auflösung: 1 h bis +78 h, danach 3 h
- Geografische Auflösung: 0,0625 ° (~7 km)
- Datenquelle: Deutscher Wetterdienst (www.dwd.de)

GFS_0,25

- Geographischer Ausschnitt: weltweit
- Aktualisierung: 4-8 mal täglich
- Vorhersagezeitraum: 0-384 h
- Zeitliche Auflösung: 1 h (bis 240h)
- Geografische Auflösung: 0,25 ° (~15 km)
- Datenquelle: NCEP (www.weather.gov/ncep/)

2.2.1.2 Statistische Wettermodelle (MOS...“Model Output Statistics“)

„Model Output Statistics“ sind Modelle, die die Ergebnisse (DMOs) von NWP-Modellen weiterbearbeiten („post processing“) und verbessern. Es werden statistische und mathematische Methoden angewendet (lineare Regressionen, quadratische Funktionen, machine learning, neurale Netzwerke, support vectors, usw.) um Vorhersagen von NWP-Modellen mit dem tatsächlichen Zustand (Messwerte, Zeitreihen) zu vergleichen. Für diese Methoden sind Trainingszeiträume in der Vergangenheit notwendig. Für diese Trainingszeiträume (1 - 3 Jahre) werden die Vorhersageresultate (DMOs) mit Messwerten verglichen und als Resultat die ursprünglichen DMO-Werte durch statistische Modelle korrigiert. Das Ergebnis impliziert das statistische Wissen über das Mikroklima und orographische Aspekte des Vorhersageortes. Dadurch können systematische Fehler des Vorhersagemodells eliminiert werden und dies führt zu besseren, „punktgenauen“ Prognosen. Neben den Modellvariablen eines NWP-Modells (z.B. Temperatur und Strahlung) können MOS-Prognosen auch für beliebige wetterabhängige Parameter (z.B. Windkraft und PV-Erzeugung, Leistung von Wärmepumpen und Fernwärmenetzen) erstellt werden, sofern für diese Parameter historische Zeitreihen, d. h. Messwerte aus der Vergangenheit, zur Verfügung stehen.



Abbildung 4: Standort des Windparks Spörbichl (Ourpower)

Für das Projekt werden die Ergebnisse des statistischen Prognosetools BLUE FORECAST (Blue Sky) verwendet.

2.2.1.3 DMO-BS-Methode

Um PV-Prognosen aus DMO-Werten berechnen zu können, ohne dass ein eigenes MOS-Training notwendig ist, wurde durch eine Gegenüberstellung von historischen Globalstrahlungsdaten und historischen PV-Erzeugungsdaten eine Korrelation ermittelt. Mit dieser ist es möglich, aus einer reinen Strahlungsprognose (DMO) mit Anwendung eines Faktors (uhrzeitabhängig Funktion) die PV-Erzeugung näherungsweise vorherzuberechnen. Diese modifizierte Methode wird im Anschluss als „DMO-BLUESKY-Methode (DMO-BS)“ bezeichnet.

2.2.1.4 Weitere Methoden für Spezialfälle

Für kurzfristige Prognosezeiträume im Sekunden-, Minuten- bis Stundenbereich erzielt die Persistenzmethode („So wie es derzeit ist, wird es auch in Zukunft sein“) verwertbare Ergebnisse, dazu sind aktuelle Messwerte von Wetterstationen, Erzeugungsdaten und Energieverbräuche notwendig. Für die kurzfristige Vorhersage von speziellen Wetterphänomenen wie Kaltluftseen, Nebelauflösung können zudem auch Messwerte von umliegenden Wetterstationen herangezogen werden.

Vorhersageparameter

Globalstrahlung

Die Globalstrahlung ist die Summe der direkten und diffusen Solarstrahlung. Die Globalstrahlung auf eine horizontale Fläche (GHI) steht als Modellvariable (DMO) und für Orte mit einer Strahlungsmessung auch als MOS-Ergebnis zur Verfügung. Mithilfe von empirischen, geometrischen Formeln (z.B. Perez-Modell) kann die Solarstrahlung für beliebig geneigte und orientierte Flächen (wie z.B. Solarpanele, Fensterflächen) vorhergesagt werden.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 5: Beispiel einer Globalstrahlungsprognose 0-72 h, DMO: schwarz, MOS: grün, Messwert: rot

Erzeugungsprognosen

Stehen historische Daten der Energieerzeugung (wie z. B. Stromerzeugungsdaten von Windkraftanlagen, PV-Anlagen, Wasserkraftwerke) zur Verfügung, so können für diese Parameter statistische MOS-Prognosen erstellt werden.

PV-Anlagen

Während des Projekts wurden MOS-Prognosemodelle für die PV-Erzeugung sowohl für Einzel- und Kleinanlagen als auch für große PV-Parks, wie beispielsweise den PV-Park Strem von OurPower mit einer installierten Leistung von 1566 kWp, entwickelt.




Abbildung 6: Beispiel einer PV-Prognose (MOS) für Strem/OurPower, MOS: blau, Messwerte: rot




Abbildung 7: Beispiel einer PV-Prognose (MOS) für Großschönau, MOS: blau, Messwerte: rot

Um PV-Prognosen aus DMO-Werten berechnen zu können, ohne dass ein eigenes MOS-Training notwendig ist, wurde durch eine Gegenüberstellung von historischen Globalstrahlungsdaten und historischen PV-Erzeugungsdaten eine Korrelation ermittelt. Mit dieser ist es möglich, aus einer reinen Strahlungsprognose (DMO) mit Anwendung eines Faktors (uhrzeitabhängig Funktion) die PV-Erzeugung näherungsweise vorherzuberechnen. Diese modifizierte Methode wird im Anschluss als „DMO-BLUESKY-Methode (DMO-BS)“ bezeichnet.

Windkraft

Vom Windpark Spörbichl (2 Windräder mit jeweils 660 kWp) standen historischen Erzeugungsdaten zur Verfügung. Im Rahmen des Projekts wurden statistische Windkraftmodelle (MOS) für diesen Standort berechnet, Vorhersagezeitraum 0-120 h.




Abbildung 8: Beispiel einer Windkraft-Erzeugungsprognose für den Windpark Spörbichl, MOS: blau, Messwerte: rot

Reine DMO-Modelle wurden im Projekt für die Windkraft nicht gerechnet, dafür standen keine Algorithmen und Anlagendaten zur Verfügung.

2.2.2 Methoden: Datenbasierte PV-Produktionsmethoden

2.2.2.1 Datenbeschreibung und –aufbereitung

In diesem Abschnitt stellen wir datenbasierte Methoden zur Erstellung von Prognosen für die PV-Produktion in Wohngebäuden vor. In der folgenden Abbildung zeigen wir ein Beispiel von PV-Produktionsmessungen in einer kleinen Energiegemeinschaft von drei Wohngebäuden in Wels, Oberösterreich.




Abbildung 9: PV-Produktion von drei Haushalten (in Wels, Oberösterreich) im Mai 2016.

Messungen der PV-Erzeugung über einen Zeitraum von mehreren Monaten reichen aus, um zuverlässige Day-Ahead-Prognosemodelle zu erstellen, bei denen Prognosen der PV-Erzeugung für den folgenden Tag erstellt werden (d. h. eine Reihe von $n = 96$ Vorhersagen für die 15-Minuten-Intervalle des folgenden Tages). Wir werden den Term $y_d(t)$ verwenden, um die Messung der PV-Produktion zum Zeitpunkt t und am Tag d zu bezeichnen, und $\hat{y}_d(t)$, um die PV-Produktion zum Zeitpunkt t und am Tag d zu bezeichnen.

In diesem Abschnitt werden die wichtigsten Prognosemethoden zur Vorhersage der PV-Erzeugung von Einzelhaushalten und Haushaltsgemeinschaften ausführlich beschrieben. Unser Hauptaugenmerk liegt dabei auf der Entwicklung von Prognosemethoden, die a) rechnerisch effizient (Ad-hoc-Berechnung von Prognosen auch in Echtzeit möglich) und b) zuverlässig in Bezug auf die abgeleiteten Prognosen sind. Zu diesem Zweck haben wir die folgenden Schlüsselmethoden untersucht:

- Persistenzmodelle
- Persistenzbasiertes autoregressives Modell (PAR)
- Persistenzbasiertes autoregressives Modell + Wetter (PAR-W)

Die erste Klasse von Modellen (Persistenzmodelle) verwendet das zuletzt beobachtete Verhalten über einen Zeitraum von einigen Tagen. Einfach ausgedrückt: Persistenzmodelle versuchen, das beobachtete Verhalten über mehrere (letzte) Tage zu erfassen. Die zweite Klasse von Modellen (PAR, PAR-W) kombiniert Persistenzmodelle mit auf Autoregression basierenden Modellen und Wettervorhersagedaten. Zusätzlich zu den persistenten (niederfrequenten) Phänomenen erfassen solche Modelle auch zeitliche Abhängigkeiten des zuvor beobachteten Verhaltens innerhalb eines Tages.

a. Persistenzmodelle ("N-days")

Persistenzprognosemodelle werden in der Regel zur Erstellung von Referenzmodellen verwendet, die dann für eine vergleichende Analyse mit fortgeschrittenen Prognosemodellen herangezogen werden können. Persistenzmodelle beruhen auf dem einfachen Prinzip, dass "die Dinge gleich bleiben", d.h. die Prognose entspricht der letzten bekannten Messung. Im Zusammenhang mit Day-Ahead-Prognosen definieren wir ein Persistenzmodell so, dass die PV-Erzeugung zum Zeitpunkt t des Tages d mit der entsprechenden Erzeugung zum gleichen Zeitpunkt t am Vortag $d - 1$ oder am Vortag $d - 7$ identisch ist. Weitere Versionen solcher Modelle würden auch mehr als einen Vortag berücksichtigen (z. B. die durchschnittliche Produktion zur gleichen Zeit über N Vortage).

Das 1-Tages-Persistenzmodell geht davon aus, dass $\hat{y}_d^{PM}(t) = y_{d-1}(t)$ ist. Analog dazu können wir das N -day-Persistenzmodell (oder kurz N -day) wie folgt definieren

$$\hat{y}_d^{PM}(t) = \frac{1}{N} \sum_{i=d-N}^{d-1} y_i(t)$$

b. Autoregressiv (AR) basiertes Modell

Wie wir im vorigen Unterabschnitt gesehen haben, versucht das diskutierte Persistenzmodell, zeitliche Abhängigkeiten zu erfassen, deren Häufigkeit sich über mehrere Tage erstreckt (z. B. aufgrund von Ähnlichkeiten im Tagesprofil der PV-Produktion). Wir werden solche Abhängigkeiten als niederfrequente zeitliche Abhängigkeiten bezeichnen.

Es kann jedoch auch zeitliche Abhängigkeiten der PV-Erzeugung innerhalb desselben Tages geben. Es ist daher sehr wahrscheinlich, dass die zum Zeitpunkt t gemessene Produktion von der zum vorangegangenen Zeitpunkt $t - 1$ desselben Tages gemessenen Produktion abhängt, insbesondere wenn der zeitliche Abstand zwischen diesen beiden Zeitpunkten eher klein ist (wir nehmen hier Zeitabstände von 15 min an). Wir werden solche zeitlichen Abhängigkeiten der Produktion als hochfrequente zeitliche Abhängigkeiten bezeichnen.

Autoregressive (AR-)Prognosemodelle können verwendet werden, um solche (hochfrequenten) zeitlichen Abhängigkeiten der Produktion innerhalb eines Kalendertages zu erfassen. Das wohl einfachste Modell dieser Art ist das autoregressive Modell (kurz AR-Modell), nach dem die Vorhersage der Produktion zum Zeitpunkt $t + 1$ durch eine lineare Kombination der Produktion zu früheren Zeitpunkten gegeben ist. Es gilt also Folgendes:

$$\hat{y}_d^{AR}(t) = a_1 y_d(t - 1) + a_2 y_d(t - 2) + \dots + a_j y_d(t - j)$$

(das sich aus einem Maximum-a-posteriori Prädiktor eines ursprünglichen Weißrausch-Störprozesses ergibt).

Falls wir Vorhersagen über mehrere Zeitinstanzen im Voraus (in der Regel einen Tag im Voraus) erstellen möchten, dann können wir eine Variation des obigen Modells implementieren, die in der Regel als Pseudo-Regressionsmodell bezeichnet wird und die folgende Form annimmt:

$$\hat{y}_d^{AR}(t) = a_1 \hat{y}_d^{AR}(t - 1) + a_2 \hat{y}_d^{AR}(t - 2) + \dots + a_j \hat{y}_d^{AR}(t - j)$$

Mit anderen Worten, wenn die Last zum Zeitpunkt $t - k$, $k = 1, \dots, j$, nicht bekannt ist, wird sie durch die für diesen Zeitpunkt verfügbare Vorhersage ersetzt.

Beachten Sie, dass alternative Auto-Regressive Modelle definiert werden können. Beispielsweise werden häufig Modelle verwendet, die auch Moving-Average (MA) Rausch-Terme enthalten. Solche Moving-Average Terme können verwendet werden, um die Auswirkungen niederfrequenten Rauschens im Profil zu erfassen. Unsere Untersuchung zeigt jedoch, dass der Gewinn an Vorhersagegenauigkeit durch das Hinzufügen solcher Terme vernachlässigbar ist.

Einer der Hauptnachteile solcher Methoden ist die Tatsache, dass sie eher für kurzfristige Zukunftsprognosen (im Bereich von wenigen Stunden) geeignet sind. Tatsächlich ist es einfach zu erkennen, dass sich selbst kleine Prognosefehler in den kurzfristigen Prognosen unvorhersehbar ausbreiten können, wenn man langfristige Zukunftsprognosen formuliert, die sich über einen Tag im Voraus erstrecken. Aus diesem Grund stellen wir im nächsten Unterabschnitt eine Kombination aus dem im vorherigen Abschnitt beschriebenen N -day-Persistenzmodell und dem oben beschriebenen AR-basierten Modell vor.

c. Persistenzbasiertes autoregressives Modell (PAR und PAR-W)

Wie bereits erwähnt, können die Persistenzmodelle niederfrequente zeitliche Abhängigkeiten im PV-Erzeugungsprofil (über mehrere Tage oder Wochen) erfassen, während autoregressive Modelle dies für hochfrequente zeitliche Abhängigkeiten (innerhalb desselben Kalendertages) tun können. Außerdem funktionieren autoregressive Modelle nur innerhalb eines kurzfristigen Zeithorizonts gut. Zu diesem Zweck möchten wir in diesem Unterabschnitt auch die Möglichkeit einer optimalen Kombination der beiden Modelltypen in Betracht ziehen. Im Prinzip passt diese Idee gut zu den expertenbasierten Prognosemethoden. Diese Idee der Modellkombinationen wird in einem späteren Abschnitt für die adaptive Auswahl und Mischung von Modellen verwendet.

Kurz gesagt setzt solch eine optimale Kombination der beiden Prognoseverfahren eine kombinierte Vorhersage der folgenden Form voraus:

$$\hat{y}_d^{AR}(t) = a_1 \hat{y}_d^{AR}(t-1) + a_2 \hat{y}_d^{AR}(t-2) + \dots + a_j \hat{y}_d^{AR}(t-j) + b_0 \hat{y}_d^{PM}(t)$$

In diesem Fall möchten wir eine neue Menge von Gewichten $a_1, a_2, \dots, a_j, b_0$ berechnen, die die optimale Kombination aus den hochfrequenten zeitlichen Abhängigkeiten (erfasst durch die auto-regressiven Terme) und den niederfrequenten zeitlichen oder saisonalen Abhängigkeiten (erfasst durch den abschließenden Persistenzterm) finden.

Es ist offensichtlich, dass die PV-Produktion mit den Wetterbedingungen (z. B. der Sonneneinstrahlung) korreliert. Da in diesem Projekt auch Vorhersagen über die Außentemperatur und die Sonneneinstrahlung verfügbar sind, beziehen wir diese Vorhersagen in das PAR-Modell ein, wodurch das Modell PAR-W entsteht (wobei "W" für Wetter steht). Genauer gesagt, kann die Vorhersage wie folgt geschrieben werden:

$$\hat{y}_d^{AR}(t) = a_1 \hat{y}_d^{AR}(t-1) + a_2 \hat{y}_d^{AR}(t-2) + \dots + a_j \hat{y}_d^{AR}(t-j) + b_0 \hat{y}_d^{PM}(t) + c_0 \hat{s}_d(t)$$

wobei $\hat{s}_d(t)$ die Schätzung der Sonneneinstrahlung des Tages d im Zeitintervall t bezeichnet.

2.3 AP4: Datengetriebene Lastprognoseplattform und Systemsicherheit

Aus den in AP2 gewonnenen Lastprofilen für unterschiedliche Familientypologien bzw. Arten von Unternehmen wurde ein Lastprognosetool für Mehrparteienhäuser entwickelt. Die angenäherten Lastprofile können mit dem Tool durch Eingabe des Jahresenergiebedarfs auf die verschiedenen definierten Lastprofiltypen rückgerechnet werden und ergeben Gesamtlastprofile für Mehrparteienhäuser. Eine Erweiterung auf ein Cluster bzw. ein Quartier ist möglich und kann so auch für EEGs genutzt werden. Die Verbrauchsprofile werden weiterhin bei Vorliegen neuer mit SmartMeter gemessenen Datensätze erweitert, um die Planungsvorhersagen bei EEGs zu verbessern.

Wir präsentieren eine detaillierte Beschreibung der entwickelten und angewandten Methoden für die Lastprognose in Wohngebäuden und Gebäudegemeinschaften. Die Hauptrichtungen der Entwicklung lassen sich wie folgt zusammenfassen: i) Verbesserung der meteorologischen Temperatur-, Strahlungs- und Lastvorhersage bei extremen Wetterbedingungen, ii) datenbasierte Standardlastvorhersagemodelle und iii) datenbasierte fortgeschrittene Lastvorhersagemodelle. Bei (i) liegt ein Schwerpunkt auf der Vorhersagbarkeit von meteorologischen Phänomenen, die für den Energieverbrauch entscheidend sind und räumlich (Kaltluftseen) und zeitlich (z.B. Hitzewellen, Dauernebel) auftreten können. Hier werden statistische Methoden zur Berechnung der Heiz- und Kühllasten eingesetzt. In (ii) konzentrieren wir uns

auf standardmäßige datenbasierte Vorhersagetechniken und kombinieren Persistenzmodelle mit Black-Box-Zeitreihenvorhersagemodellen (z. B. autoregressive Modelle mit saisonalen Trends). In (iii) entwickeln wir Erweiterungen von Standardmodellen, indem wir a) alternative Basismodelle desselben oder eines anderen Gebäudes adaptiv kombinieren (oder zwischen ihnen wechseln) (Transfer-Lernen) und b) inferenzbasierte Modellierung für die Entdeckung von Mustern im Nutzerverhalten und die Modellsynthese, die auch die Möglichkeit von Vorhersagen mit User-in-the-Loop einschließen kann. Die Methodik für (i) wurde im vorhergehenden Abschnitt vorgestellt und wird hier übersprungen. Die Methoden für (ii) und (iii) werden unten vorgestellt.

2.3.1 Daten-basierte Lastprognosemethoden

Messungen des Lastverbrauchs jedes Haushalts wurden mit einer Granularität von 15 Minuten gesammelt. Damit stehen uns an jedem Tag $n = 96$ sequentielle Messungen der unflexiblen Last aus jedem Haushalt zur Verfügung. Jede dieser Messungen zum Zeitpunkt t stellt die Summe des Lastverbrauchs während des letzten 15min-Intervalls dar, d.h. den Energieverbrauch innerhalb des letzten 15min-Intervalls. In der folgenden Abbildung 10 ist ein Beispiel für den gemessenen Lastverbrauch von drei Haushalten (in Wels, Oberösterreich) innerhalb eines Monats dargestellt.




Abbildung 10 Lastverbrauch von drei Haushalten (in Wels, Oberösterreich) in einem Monat (von 01.01.2016 bis 31.01.2016).

Messungen der Stromlast über einen Zeitraum von mehreren Monaten reichen aus, um zuverlässige Day-Ahead-Prognosemodelle zu erstellen, bei denen Prognosen der Stromlast für den folgenden Tag erstellt werden (d. h. eine Reihe von $n = 96$ Vorhersagen über die 15-Minuten-Intervalle des folgenden Tages). Wir werden den Buchstaben $y_d(t)$ verwenden, um die Messung der Stromlast zum Zeitpunkt t und am Tag d zu bezeichnen, und $\hat{y}_d(t)$, um die Prognose der Stromlast zum Zeitpunkt t und am Tag d zu bezeichnen.

In diesem Abschnitt werden die wichtigsten Prognosemethoden zur Vorhersage der Stromlast einzelner Haushalte und von Haushaltsgemeinschaften im Detail beschrieben. Unser Hauptaugenmerk liegt auf der Entwicklung von Prognosemethoden, die a) rechentechnisch effizient (ermöglicht eine Ad-hoc-Berechnung der Prognosen auch in Echtzeit) und b) zuverlässig in Bezug auf die abgeleiteten Prognosen sind. Zu diesem Zweck haben wir die folgenden wichtigsten Methoden untersucht:

- Persistenzmodelle
- Autoregressiv (AR) basiertes Modell
- Holt-Winters Modell

- d. SARIMA Modell
- e. Persistenzbasiertes autoregressives Modell (PAR)
- f. Saisonaler Persistenz basierendes, regressives Modell (SPR)
- g. Saisonaler Persistenz basierendes neuronales Netzmodell (SPNN)
- h. Verallgemeinertes additives Modell auf der Grundlage des Prophet-Algorithmus von Facebook (Prophet)
- i. Long Short-Term Memory Model (LSTM)

Die erste Klasse von Modellen (Persistenzmodelle) verwendet das zuletzt beobachtete Verhalten über einen Zeitraum der letzten Tage. Einfach gesagt, Persistenzmodelle versuchen, das beobachtete Verhalten über mehrere (letzte) Tage zu erfassen. Die zweite Klasse von Modellen (Auto-Regressive-basierte Modelle) verwendet das zuletzt beobachtete Verhalten während des aktuellen Tages (der letzten Stunden), um eine Vorhersage für die nächsten Stunden zu erstellen. Kurz gesagt, Auto-Regressive-basierte Modelle erfassen zeitliche Abhängigkeiten von zuvor beobachtetem Verhalten innerhalb eines Tages. Informell können wir sagen, dass Persistenzmodelle versuchen, niedrige Frequenzen in den Profilen der Last zu erfassen, während Auto-Regressive-basierte Modelle versuchen, höhere Frequenzen in den Profilen der Last zu erfassen.

Eine wichtige Beobachtung bei der Untersuchung dieser Methoden ist, dass eine Kombination der beiden Methoden (a) und (b) genauere Vorhersagen über die Lasten liefern sollte. Wir möchten sowohl die nieder- als auch die hochfrequenten Phänomene erfassen, die auftreten können. Diese Notwendigkeit wird auch dadurch begründet, dass der große Zeithorizont der angeforderten Prognosen (in der Regel 1 Tag im Voraus) zusätzliche Herausforderungen (z.B. seltene Ereignisse) mit sich bringt, die mit keiner der beiden Methoden allein erfasst werden können. Wir untersuchen die Kombination der beiden Modelle in der Modellkategorie (e).

Diese Idee (der Kombination alternativer Modelle und Faktoren innerhalb eines einzigen Modells) wurde in den Modellkategorien (f) und (g) weiter ausgenutzt; dabei wird versucht, eine größere Anzahl von Merkmalen zu integrieren (d. h. eine größere Variation von nieder- und hochfrequenten Persistenzfaktoren) und eine optimale Auswahl unter ihnen zu treffen (entweder unter Verwendung einer Regression oder eines neuronalen Netzes). Diese Modelle, nämlich SPR und SPNN, nutzen die Integration von kausalen Effekten, die normalerweise im Verhalten von Menschen vorhanden sind. So verhalten sich die Menschen beispielsweise jeden Morgen in Bezug auf den Stromverbrauch in etwa gleich. Das bedeutet, dass das jüngste Stromverbrauchsprofil eine Menge Informationen über den kommenden Stromverbrauch liefert. Die Integration eines solchen kausalen Verhaltens gehört zu den Zielen der Tasks 4.2 und 4.3 von AP4.

Die Modellkategorien (c) und (d) stellen zwei eher standardisierte Ansätze dar, nämlich das Holt-Winters-Modell und das SARIMA-Vorhersagemodell. Beide Ansätze versuchen, sowohl nieder- als auch hochfrequente Muster zu erfassen, und sie sind speziell für die Vorhersage von saisonalen Zeitreihen konzipiert. Im Wesentlichen handelt es sich bei SARIMA um eine Erweiterung des klassischen ARIMA-Modells, das Trägheit, Tendenz und Rauschen in den Datensätzen berücksichtigt und auch die Saisonalität einbezieht. In ähnlicher Weise versucht auch das Holt-Winters-Modell, verschiedene Komponenten in den Zeitreihen zu erfassen, einschließlich Level, Trend, und Saisonkomponenten.

Wir haben auch die Leistung des auf dem Prophet-Algorithmus von Facebook basierenden Generalized Additive Model (Prophet) und der Long Short-Term Memory (LSTM)-Modelle aufgrund ihrer jüngsten

Erfolge bei Vorhersageaufgaben bewertet. Wir müssen erwähnen, dass diese Modelle als Black-Box-Ansätze betrachtet werden, die nicht unbedingt für Lastvorhersageaufgaben konzipiert sind.

Unser Ziel ist es, einen Vergleich zwischen dieser großen Sammlung von Standardmodellen anzustellen und den Unterschied zwischen den Modellen (e, f und g), die speziell auf die Lastprognose zugeschnitten sind, und den allgemeinen Black-Box-Modellen, wie den Modellen (a, c, d, h und i), zu ermitteln. Dieser Vergleich bietet auch die Möglichkeit, die Bedeutung der Erfassung kausaler Phänomene zu bewerten, wie sie von den Methoden f und g erfasst werden. In den folgenden Unterabschnitten stellen wir die Einzelheiten der oben genannten Methoden vor.

a. Persistenzmodelle ("N-same-days" und "N-days")

Persistenzprognosemodelle werden in der Regel zur Erstellung von Referenzmodellen verwendet, die dann für eine vergleichende Analyse mit fortgeschrittenen Prognosemodellen herangezogen werden können. Persistenzmodelle beruhen auf dem einfachen Prinzip, dass "die Dinge gleich bleiben", d.h. die Prognose entspricht der letzten bekannten Messung. Im Zusammenhang mit Day-Ahead-Prognosen definieren wir ein Persistenzmodell so, dass die Stromlast zum Zeitpunkt t des Tages d mit der entsprechenden Last zum gleichen Zeitpunkt t am Vortag $d - 1$ oder am Vortag $d - 7$ identisch ist. Weitere Versionen solcher Modelle würden auch mehr als einen Vortag berücksichtigen (z. B. den durchschnittlichen Verbrauch zur gleichen Zeit über N Vortage).

Das 1-Tages-Persistenzmodell geht davon aus, dass $\hat{y}_d^{PM}(t) = y_{d-1}(t)$ ist. Analog dazu können wir das N -day-Persistenzmodell (oder kurz N -day) wie folgt definieren

$$\hat{y}_d^{PM}(t) = \frac{1}{N} \sum_{i=d-N}^{d-1} y_i(t)$$

Da die Stromlast in hohem Maße mit der Anwesenheit der Bewohner in einem Haushalt (d. h. mit dem Zeitplan der Bewohner) korreliert, können wir das obige N -day-Persistenzmodell weiter verbessern, indem wir nur die N vorhergehenden gleichen Tage berücksichtigen. Wenn d einem "Montag" entspricht, dann müssen wir, um unsere Prognose für den Zeitpunkt t zu erstellen, die durchschnittliche Last zur gleichen Zeit an den letzten N vorangegangenen Montagen ermitteln. Wir werden dieses Modell als N -Same-Days-Persistenzmodell oder kurz N -Same-Days bezeichnen, bei dem die Prognosen wie folgt berechnet werden

$$\hat{y}_d^{PM}(t) = \frac{1}{N} \sum_{i=1}^N y_{d-\tau_i}(t)$$

b. Autoregressiv (AR) basiertes Modell

Wie wir im vorherigen Unterabschnitt gesehen haben, versuchen die diskutierten Persistenzmodelle, zeitliche Abhängigkeiten zu erfassen, deren Häufigkeit sich über mehrere Tage oder Wochen erstreckt (z.B. aufgrund von Ähnlichkeiten im Tagesablauf der Bewohner an denselben Tagen). Wir werden solche Abhängigkeiten als niederfrequente zeitliche Abhängigkeiten bezeichnen.

Es kann aber auch zeitliche Abhängigkeiten der Stromlast innerhalb desselben Tages geben. Es ist demnach sehr wahrscheinlich, dass die zur Tageszeit t gemessene Last von der zur vorherigen Zeitinstanz $t - 1$ desselben Tages gemessenen Last abhängt, vor allem wenn das Zeitintervall zwischen diesen beiden Zeitinstanzen eher klein ist (hierbei gehen wir von Zeitintervallen von 15min aus). Wir werden solche zeitlichen Abhängigkeiten der Last als hoch frequente zeitliche Abhängigkeiten bezeichnen.

Mit Hilfe von Auto-Regressive (AR) Prognosemodellen können solche (hochfrequenten) zeitlichen Abhängigkeiten der Last innerhalb eines Kalendertages erfasst werden. Das wahrscheinlich einfachste derartige Modell ist das Auto-Regressive Modell (kurz AR-Modell), nach dem die Vorhersage der Last zum Zeitpunkt $t + 1$ durch eine lineare Kombination der Last zu früheren Zeitpunkten gegeben ist. Es gilt also:

$$\hat{y}_d^{AR}(t) = a_1 y_d(t-1) + a_2 y_d(t-2) + \dots + a_j y_d(t-j)$$

(das sich aus einem Maximum-a-posteriori Prädiktor eines ursprünglichen Weißrausch-Störprozesses ergibt [1]).

Falls wir Vorhersagen über mehrere Zeitinstanzen im Voraus (in der Regel einen Tag im Voraus) erstellen möchten, dann können wir eine Variation des obigen Modells implementieren, die in der Regel als Pseudo-Regressionsmodell bezeichnet wird und die folgende Form annimmt:

$$\hat{y}_d^{AR}(t) = a_1 \hat{y}_d^{AR}(t-1) + a_2 \hat{y}_d^{AR}(t-2) + \dots + a_j \hat{y}_d^{AR}(t-j)$$

Mit anderen Worten, wenn die Last zum Zeitpunkt $t - k$, $k = 1, \dots, j$, nicht bekannt ist, wird sie durch die für diesen Zeitpunkt verfügbare Vorhersage ersetzt.

Beachten Sie, dass alternative Auto-Regressive Modelle definiert werden können. Beispielsweise werden häufig Modelle verwendet, die auch Moving-Average (MA) Rausch-Terme enthalten. Solche Moving-Average Terme können verwendet werden, um die Auswirkungen niederfrequenten Rauschens im Profil zu erfassen. Unsere Untersuchung zeigt jedoch, dass der Gewinn an Vorhersagegenauigkeit durch das Hinzufügen solcher Terme vernachlässigbar ist.

Einer der Hauptnachteile solcher Methoden ist die Tatsache, dass sie eher für kurzfristige Zukunftsprognosen (im Bereich von wenigen Stunden) geeignet sind. Tatsächlich ist es einfach zu erkennen, dass sich selbst kleine Prognosefehler in den kurzfristigen Zukunftsprognosen unvorhersehbar ausbreiten können, wenn man langfristige Zukunftsprognosen formuliert, die sich über einen Tag im Voraus erstrecken. Aus diesem Grund stellen wir im nächsten Unterabschnitt eine Kombination aus dem im vorherigen Abschnitt beschriebenen N -same-day/ N -day-Persistenzmodell und dem oben beschriebenen AR-basierten Modell vor.

c. Holt-Winters (HW) Modell

Im Gegensatz zu den vorhergehenden Modellen versucht das Holt-Winters-Modell (HW-Modell), sowohl saisonale Phänomene als auch zeitliche Trends zu erfassen. Die saisonale Komponente in diesem Modell versucht, die wiederholten Schwankungen zu erklären, und sie wird durch die Länge der Saison charakterisiert, d. h. den Zeitraum, nach dem die Wiederholung der Schwingungen beginnt [2]. In unseren Daten wird die Länge der Saison auf 96×7 festgelegt (wobei 96 der täglichen Saisonalität und 7 der schwachen Saisonalität entspricht), was zu 672 saisonalen Komponenten führt, eine für jedes T -Intervall an einem Wochentag. Insbesondere ist die zukünftige Schätzung einer Menge y zum Zeitpunkt t nach dem HW-Modell gegeben durch:

$$\hat{y}_d^{HW}(t) = L(t-n) + n P(t-n) + S(t-T)$$

wobei $L(t) = \alpha(y(t) - S(t-T)) + (1-\alpha)(L(t-1) + P(t-1))$ die Niveauekomponente, $P(t) = \beta(L(t) - L(t-1)) + (1-\beta)P(t-1)$ die Trendkomponente und $S(t) = \gamma(y(t) - L(t)) + (1-\gamma)S(t-T)$ ist. Wir haben die Notation $n = 96$ verwendet, $\alpha \in (0,1)$ ist der Datenglättungsfaktor, $\beta \in (0,1)$ ist der Trendglättungsfaktor und $\gamma \in (0,1)$ ist der Glättungsfaktor für saisonale Veränderungen. Die Parameter α, β, γ müssen identifiziert werden. Ähnlich wie bei dem zuvor vorgestellten Pseudoregressionsmodell

werden die Werte von $y(t)$ zu früheren Zeitpunkten, wenn sie nicht verfügbar sind, durch die entsprechenden Schätzungen ersetzt.

Im HW-Modell versucht die Pegelkomponente, ein Basislastniveau (oder eine Referenz) zu erfassen, während die Trendkomponente (durch einen Tiefpassfilter) annähert, wie sich die Pegelkomponente mit der Zeit (innerhalb weniger Tage) verändert. Die Saisonkomponente schließlich versucht, Abhängigkeiten mit geringerer Frequenz (über längere Zeiträume) zu erfassen. Insgesamt kann man sich das HW-Modell als eine Kombination aus hoch- und niederfrequenten zeitlichen Abhängigkeiten vorstellen.

d. Modell des saisonalen autoregressiven integrierten gleitenden Durchschnitts (SARIMA)

Das ARIMA-Modell (Auto Regressive Integrated Moving Average) ist eine der gängigsten Methoden zur Analyse und Prognose von Zeitreihen. Es handelt sich um eine Erweiterung der ARMA-Modelle für nicht-stationäre Zeitreihen, die stationär gemacht werden können, indem Unterschiede einer bestimmten Ordnung von der ursprünglichen Zeitreihe - integrierte oder differenzstationäre Zeitreihen - übernommen werden.

ARIMA verwendet Hauptparameter (p, d, q) , die als ganze Zahlen ausgedrückt werden. Diese drei Parameter berücksichtigen zusammen Saisonalität (Periodizität), Tendenz und Rauschen in den Datensätzen:

- p ist die auto-regressive Ordnung, die es ermöglicht, frühere Werte der Zeitreihe zu berücksichtigen.
- d ist die Reihenfolge der Integration, die es ermöglicht, frühere Unterschiede der Zeitreihe zu berücksichtigen,
- q ist die Reihenfolge des gleitenden Mittelwerts, die es ermöglicht, den Modellfehler als lineare Kombination von zuvor beobachteten Fehlerwerten einzustellen.

Der Hauptnachteil dieses Modells ist, dass es keine saisonalen Zeitreihen unterstützt, was es unmöglich macht, damit Zeitreihen des Energieverbrauchs vorherzusagen, die durch starke Periodizität gekennzeichnet sind, wie z.B. Tages- oder Wochenzeiten.

Eine Variation des ARIMA-Modells, nämlich SARIMA, kann stattdessen verwendet werden, um auch die Periodizität zu verfolgen. In diesem Modell sind die Parameter (p, d, q) die nicht-saisonalen Parameter, die wie oben beschrieben gleich bleiben. Zusätzlich zu diesen Parametern stellen wir auch Parameter (P, D, Q) vor, die ähnlich wie (p, d, q) definiert sind, aber stattdessen für die saisonale Komponente der Zeitreihe gelten. Schließlich beschreibt der Parameter S den Zeitraum der Saison in der Zeitreihe (96, wenn die Periode einem Tag entspricht, 7×96 , wenn die Periode einer Woche entspricht, etc., wobei 96 sich auf die Granularität der Sensordaten innerhalb eines Tages bezieht). Ähnlich wie das Holt-Winters-Modell ist dies auch ein Black-Box-Modell, das auch die saisonalen Effekte erfasst und verwendet wird, um die Leistung der abgeleiteten, Auto-Regressive Prognosemodelle besser zu bewerten.

e. Persistenzbasiertes autoregressives Modell (PAR und PAR-W)

Wie bereits erwähnt können die Persistenzmodelle niederfrequente zeitliche Abhängigkeiten im Lastprofil (über mehrere Tage oder Wochen) erfassen, während Auto-Regressive-Modelle dies für hochfrequente zeitliche Abhängigkeiten (innerhalb desselben Kalendertages) können. Darüber hinaus funktionieren Auto-Regressive-Modelle nur innerhalb eines kurzfristigen Zeithorizonts gut. Zu diesem Zweck möchten wir in diesem Unterabschnitt auch die Möglichkeit einer optimalen Kombination der beiden Modelltypen

berücksichtigen. Diese Idee der Modellkombinationen wird in einem späteren Abschnitt für die adaptive Auswahl und Mischung von Modellen genutzt.

Kurz gesagt setzt solch eine optimale Kombination der beiden Prognoseverfahren eine kombinierte Vorhersage der folgenden Form voraus:

$$\hat{y}_d^{AR}(t) = a_1 \hat{y}_d^{AR}(t-1) + a_2 \hat{y}_d^{AR}(t-2) + \dots + a_j \hat{y}_d^{AR}(t-j) + b_0 \hat{y}_d^{PM}(t)$$

In diesem Fall möchten wir eine neue Menge von Gewichten $a_1, a_2, \dots, a_j, b_0$ berechnen, die die optimale Kombination aus den hochfrequenten zeitlichen Abhängigkeiten (erfasst durch die auto-regressiven Terme) und den niederfrequenten zeitlichen oder saisonalen Abhängigkeiten (erfasst durch den abschließenden Persistenzterm) finden.

Es wurde festgestellt, dass ein hoher Lastverbrauch oft mit den Wetterbedingungen (z. B. Außentemperatur und Sonneneinstrahlung) korreliert. Die Bewohner des Haushalts können beispielsweise das Wetter beobachten und die Stromlast erhöhen, wenn die PV-Energieproduktion ausreichend ist. Da in diesem Projekt auch Vorhersagen über die Außentemperatur und die Sonneneinstrahlung verfügbar sind, beziehen wir diese Vorhersagen in das PAR-Modell ein, wodurch das Modell PAR-W entsteht (wobei "W" für Wetter steht). Genauer gesagt, kann die Vorhersage wie folgt geschrieben werden:

$$\hat{y}_d^{AR}(t) = a_1 \hat{y}_d^{AR}(t-1) + a_2 \hat{y}_d^{AR}(t-2) + \dots + a_j \hat{y}_d^{AR}(t-j) + b_0 \hat{y}_d^{PM}(t) + c_0 \hat{s}_d(t)$$

wobei $\hat{s}_d(t)$ die Schätzung der Sonneneinstrahlung des Tages d im Zeitintervall t bezeichnet.

f. Saisonaler Persistenz basierendes, regressives Modell (SPR)

Standard-Persistenzmodelle formulieren Prognosen durch Mittelung des Lastverbrauchs während der gleichen Zeitintervalle an den Vortagen. Die Hauptannahme besteht darin, dass sich die Bewohner jeden Tag zur gleichen Zeit ähnlich verhalten. Wenn jedoch Prognosen mit einer feinen Granularität von 15 Minuten angefordert werden, können selbst kleine Änderungen im Zeitplan der Bewohner erhebliche Auswirkungen auf die Prognosegenauigkeit haben. So führt beispielsweise ein halbstündiger Unterschied in der Uhrzeit, zu der ein morgendlicher Zeitplan ausgeführt wird, zu großen Vorhersagefehlern am folgenden Tag.

Aus diesem Grund würden wir gerne Modelle verwenden, die robuster gegenüber kleinen Schwankungen in den Zeitplänen der Bewohner sind. Anstelle des Lastverbrauchs in demselben 15-Minuten-Intervall am Vortag können wir beispielsweise den durchschnittlichen Lastverbrauch in einem größeren Zeitfenster am Vortag (z. B. ein Stundenfenster) verwenden. Auf diese Weise können wir die Persistenz des Zeitplans der Bewohner besser erfassen, selbst bei kleinen Schwankungen der Ausführungszeiten. Darüber hinaus möchten wir die Möglichkeit einbeziehen, dass auch kausale Effekte im Verhalten der Menschen erfasst werden. Wenn zum Beispiel in den Morgenstunden bereits eine Spitze im Stromverbrauch beobachtet wurde, dann ist es sehr wahrscheinlich, dass es keine weitere Verbrauchsspitze am Morgen gibt. Solche kausalitätsbasierten Überlegungen können nicht durch Black-Box-Ansätze erfasst werden. Zu diesem Zweck führen wir in Tabelle 1 eine Reihe zusätzlicher Faktoren ein, die zur Erfassung der Modellierung des Stromverbrauchs verwendet werden könnten. Eine vorläufige Version dieses Modells wurde in [3] vorgestellt und in [4], einem Teil des Serve-U-Projekts, weiterentwickelt.

Tabelle 1 Feature-Kategorien im SPR Modell

f_d	Kennzeichen (ganzzahlige Variable) für die Art des Tages (z. B. Werktag oder Wochenende)
y	Elektrizitätslast
y_{rs}	Gesamte Stromlast in der letzten Stunde (rollierende Summe)
y_h	Gesamtstromstundenlast innerhalb des aktuellen Stundenindex
y_d	Prozentualer Anteil des Stromverbrauchs des aktuellen 15-Minuten-Intervalls am durchschnittlichen Gesamtstromverbrauch eines Tages
y_{dh}	Differenz des stündlichen Stromverbrauchs innerhalb der letzten zwei Stunden
y_{low}	Kennzeichen für niedrigen Stromverbrauch (boolesche Variable), wenn die Stromlast weniger als 20% des mittleren Lastverbrauchswertes während des Tages beträgt.
y_{high}	Kennzeichen für hohen Stromverbrauch (boolesche Variable), wenn die Stromlast mehr als 150% des mittleren Lastverbrauchswerts während des Tages beträgt

Anhand dieser Merkmale definieren wir ein lineares Regressionsmodell, bei dem die Regressoren die Werte der oben genannten Merkmale in den vorangegangenen Tagen umfassen. Die unbekannten Parameter sind in der folgenden Tabelle aufgeführt.

Tabelle 2 Merkmale, die im SPR als Regressoren betrachtet werden und zugeordnete Gewichte.

Day	f_d	y	y_{rs}	y_h	y_d	y_{dh}	y_{low}	y_{high}
Target d	α_0	-	-	-	-	-	-	-
$d - 1$	-	α_1	α_3	α_5	α_7	α_9	α_{11}	α_{13}
$d - 7$	-	α_2	α_4	α_6	α_8	α_{10}	α_{12}	α_{14}

Insbesondere haben wir für alle Faktoren außer f_d zwei Merkmale eingeführt: Das erste erfasst den Wert dieses Faktors im gleichen Zeitintervall am Vortag, das zweite den Wert dieses Faktors im gleichen Zeitintervall zur gleichen Zeit vor einer Woche. Die unbekannten Parameter $\alpha_0, \alpha_1, \dots, \alpha_{14}$ müssen identifiziert werden. Genauer gesagt, die Vorhersage zum Zeitpunkt t für den nächsten Tag d hat die folgende Form

$$\begin{aligned}
 \hat{y}_d^{SPR}(t|\alpha_0, \alpha_1, \dots, \alpha_{14}) &= \alpha_0 f_d + \alpha_1 y_{d-1}(t) + \alpha_2 y_{d-7}(t) + \alpha_3 y_{rs,d-1}(t) + \alpha_4 y_{rs,d-7}(t) + \alpha_5 y_{h,d-1}(t) + \alpha_6 y_{h,d-7}(t) \\
 &+ \alpha_7 y_{d,d-1}(t) + \alpha_8 y_{d,d-7}(t) + \alpha_9 y_{dh,d-1}(t) + \alpha_{10} y_{dh,d-7}(t) + \alpha_{11} y_{low,d-1}(t) \\
 &+ \alpha_{12} y_{low,d-7}(t) + \alpha_{13} y_{high,d-1}(t) + \alpha_{14} y_{high,d-7}(t)
 \end{aligned}$$

Es können auch alternative Varianten in Betracht gezogen werden, bei denen wir mehr als einen Vortag oder mehr als einen Vortag desselben Tages berücksichtigen.

g. Saisonaler Persistenz basierendes neuronales Netzmodell (SPNN)

Die Abhängigkeiten der Stromlast von den im SPR-Modell berücksichtigten Datenmerkmalen können nicht linear, sondern nichtlinear sein. Solche Abhängigkeiten sind möglicherweise nicht von vornherein bekannt,

können aber durch ein neuronales Netz approximiert werden. In diesem Abschnitt stellen wir eine neuronale Netzwerkformulierung des SPR-Modells vor, indem wir es als Multi-Layer Perceptron (MLP) formulieren. Wir werden dieses Modell als saisonal persistenzbasiertes neuronales Netz (SPNN) bezeichnen. Insbesondere werden die gleichen Merkmale, die für das lineare Regressionsmodell verwendet werden, auch als Eingangsmerkmale für das MLP verwendet.

Für die Konfiguration des MLP haben wir die folgenden Richtlinien verwendet: Die Eingabeschicht besteht aus einer Reihe von Neuronen, die mit den Eingabemerkmale des SPR-Modells übereinstimmen. Die versteckten Schichten wurden so konzipiert, dass sie nur wenige Knoten pro Schicht enthalten. Die Ausgabeschicht besteht aus einem einzigen Knoten (da es sich um ein Regressionsproblem handelt), der die Prognose zu einem bestimmten Zeitpunkt liefert. Als Aktivierungsfunktion haben wir die Rectified Linear Activation Function für die versteckten Schichten und die Linear Activation Function für die Ausgabeschicht verwendet. Als Verlustfunktion wurde der mittlere quadratische Fehler verwendet. Um die Anzahl der Knoten in der versteckten Schicht zu berechnen, verwenden wir die folgende Formel als Richtwert [5]

$$N_{nodes} = \frac{(4N_i^2 + 3)}{(N_i^2 - 8)}$$

wobei N_i die Anzahl der Neuronen der Eingabeschicht ist. Das resultierende neuronale Netz hat nur eine versteckte Schicht mit $N_{nodes} = 4$.

h. Verallgemeinertes additives Modell auf der Grundlage des Prophet-Algorithmus von Facebook (Prophet)

Eine detaillierte Beschreibung der Methodik, die im Prophet-Modell von Facebook implementiert wurde [6], [7]. Diese Methodik basiert auf der Human-in-the-Loop-Modellierung und bietet passende additive Regressionsmodelle (verallgemeinerte lineare Modelle und deren Erweiterung auf verallgemeinerte additive Modelle, GAM) der folgenden Form:

$$\hat{y}_d^{Prophet}(t) = g(t) + s(t) + h(t) + w_t$$

wobei $g(t)$ eine Funktion ist, die den Trend der Reihe annähert; $s(t)$ erfasst die saisonalen Schwankungen (täglich, wöchentlich usw.); $h(t)$ erfasst die Auswirkungen der Feiertage und anderer wichtiger Kalenderereignisse; und w_t stellt normalverteilte zufällige Störungen dar. Zur Approximation dieser Funktionen werden die folgenden Methoden verwendet:

- **Trend:** Er wird durch eine stückweise lineare Regression modelliert, die durch die folgende Gleichung beschrieben wird:

$$g(t) = \frac{C}{1 + e^{(-k(t-m))}}$$

wobei C die Tragfähigkeit des Modells, k die Wachstumsrate und m den Datenoffset bezeichnet. Der Trend kann auch durch eine stückweise logistische Wachstumskurve beschrieben werden:

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma)$$

$$a(t) = a_j(t) = \begin{cases} 1, & t \geq s_j \\ 0, & t < s_j \end{cases}$$

wobei k die Wachstumsrate ist; m der Verzerrungsparameter ist; s_j der Zeitpunkt der j -ten Messung der Last ist, $j = 1, 2 \dots s$; g der Glättungsoffset bei s_j ist; d der Betrag der Änderung zum Zeitpunkt t_j ist; $a(t)^T$ den Transpositionsvektor von $a(t)$ bezeichnet;

- *jährliche oder wöchentliche Saisonalität*: Sie wird durch Teilsummen einer Fourier-Reihe modelliert:

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right)$$

wobei a_n und b_n die Lernparameter sind, P die regelmäßige Periode der Lastsequenz ist und N die Anzahl der im Modell verwendeten Perioden ist;

- *"Feiertage"* (z. B. offizielle Feiertage und Wochenenden - Neujahr, Weihnachten usw. sowie andere Tage, an denen sich die Eigenschaften der Zeitreihe erheblich ändern können) werden als Indikatorvariablen für jedes unabhängige Modell getrennt dargestellt und durch die folgenden Gleichungen modelliert:

$$h(t) = \sum_{i=1}^L K_i 1(t \in D_i)$$

$$Z(t) = [1(t \in D_1) \dots 1(t \in D_L)]$$

$$h(t) = Z(t)k, k \sim \text{Normal}(0, v)$$

wobei K_i die Auswirkung des Zeitraums vor und nach einem Feiertag i mit D_i Fensterzeitraum angibt. Der Wert der Standardabweichung v bestimmt die Auswirkung des Feiertags auf das Modell, d. h. bei größeren Werten hat der Feiertag eine größere Auswirkung.

Die Schätzung der Parameter des angepassten Modells erfolgt nach den Grundsätzen der Bayes'schen Statistik. Zu diesem Zweck wird die probabilistische Programmierplattform STAN verwendet.

i. Long Short-Term Memory Model (LSTM)

Beobachtungen des Stromverbrauchs in Wohngebäuden und ihren Gemeinschaften haben gezeigt, dass die statistischen Merkmale von Woche zu Woche in engen Grenzen variieren, d. h. die Muster der wöchentlichen Schwankungen des Stromverbrauchs bleiben erhalten. Allerdings gibt es aufgrund des Nutzerverhaltens enorme Schwankungen innerhalb von Stundenintervallen. Für diese Verbrauchsfälle ist eine eingehende Analyse der täglichen Sequenzen erforderlich, die das künstliche neuronale Netz mit langem Kurzzeitgedächtnis (Long Short-term Memory, LSTM) leisten kann, da es in der Lage ist, langfristige Korrelationen zu erlernen, Zeitreihendaten in kurzfristigen Sequenzen effizient zu verarbeiten, Muster komplexer Sequenzen automatisch zu erkennen und zu erlernen und sich an wechselnde Eingabedaten anzupassen [8].




Figure 1 LSTM architecture with three main components: "forget gate", "input gate" and "output gate"

Es ist bekannt, dass beim LSTM-Lernen zunächst die Daten der Ausgangsschicht sortiert werden und dabei die Sigma-Funktion verwendet wird. Die nicht-stationären Quelldaten werden ausgeschlossen, und die verbleibenden Daten werden in den nächsten Schritt verschoben. Die Daten werden mit Hilfe des folgenden Ausdrucks sortiert:

$$f_t = \sigma(W_f[h_{t-1}, \alpha_t] + b_f),$$

wobei W_f der Eingangsgewichtungskoeffizient, h_t der Ausgangsvektor und b_f der Schwellenwert der Eingangsschicht ist.

Im nächsten Schritt werden die ausgewählten Eingabedaten trainiert, um den Vorhersageindikator zu ermitteln und dessen akzeptable Werte zu bestimmen. In diesem Prozess werden die Sigma- und die Tangens-Funktion verwendet:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i),$$

$$C_t = \tan(W_c[h_{t-1}, x_t] + b_c),$$

wobei x_t die Eingabedaten sind; b_i und b_c sind die Schwellenwerte der Neuronen.

Auf der Grundlage der ausgewählten Daten werden die Neuronen in der Ausgangsschicht durch systematische Kombination von Sigma- und Tangensfunktionen identifiziert. Das heißt, das Vorhersageergebnis wird in diesem Prozess ermittelt:

$$\begin{cases} O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = O_t \tan(C_t) \end{cases}$$

wobei O_t die mithilfe der Sigma-Funktion ausgewählten Ausgangsdaten sind; h_t ist die Ausgangsschicht des Neuronennetzes.

2.3.2 Methoden: Fortgeschrittene Daten-basierte Lastprognosemethoden

In diesem Abschnitt beschreiben wir eine Auswahl fortgeschrittener Methoden, die zur Verbesserung der Vorhersagegenauigkeit der zuvor vorgestellten Standardmodelle entwickelt wurden. Die Entwicklung dieser Modelle zielt darauf ab, zwei mögliche Probleme der Standardmodelle anzugehen, nämlich i) lange Trainingszeiten, die zu großen Vorhersagefehlern zu früheren Zeitpunkten führen, und ii) unbekannte zugrunde liegende latente Ereignisse, die zu raschen Schwankungen der Vorhersagegenauigkeit führen (z. B. aufgrund unvorhergesehener Spitzen im Lastverbrauch). Was (i) betrifft, so ist es bei mehreren Modellen häufig der Fall, dass vor dem Training ausreichend historische Daten benötigt werden. Dies gilt sowohl für Modelle, die versuchen, saisonale Trends zu erfassen, wie SARIMA und HW, als auch für Modelle mit neuronalen Netzen, wie das SPNN-Modell. Infolgedessen schneiden diese Modelle möglicherweise nicht gut ab, wenn nicht genügend Daten verfügbar sind. Was (ii) betrifft, so kann der Lastverbrauch von unbekannten (oder verborgenen) Phänomenen oder Ereignissen abhängen, z. B. von den Zeitplänen der Bewohner, Schwankungen der Außentemperatur oder anderen exogenen Faktoren, die nicht gemessen werden können. Zu diesem Zweck suchen wir nach Methoden, die sich besser an möglicherweise variierende (exogene) Bedingungen anpassen, die zu unterschiedlichen nieder- oder hochfrequenten Mustern in den Lastverbrauchsprofilen führen können. Das Ziel (i) steht im Einklang mit Task 4.4 und der Entwicklung von Transfer-Learning-Methoden, und das Ziel (ii) steht im Einklang mit den Task 4.2-4.3 und der Entwicklung von kausal-inferenzbasierten Lastprognosemodellen.

Um die Probleme im Zusammenhang mit den Punkten (i) und (ii) zu lösen, haben wir drei alternative Techniken untersucht und entwickelt, und zwar:

- a. Adaptive Modellumschaltung

- b. Ensemble-Modellierung
- c. Transfer-Learning-basierte Lastprognose und Ensemble-Modellierung
- d. Auf Kausal-Inferenz basierende Lastprognosen

Bei der ersten Technik (a) der adaptiven Modellumschaltung wird versucht, die Vorhersagegenauigkeit der Modelle zu verbessern, indem adaptiv auf das beste Modell umgeschaltet wird (adaptive Modellumschaltung). Bei der zweiten Technik (b) werden verschiedene Modelle optimal kombiniert (Ensemble-Modellierung). Die dritte Technik (c) führt eine Ensemble-Modellierung durch, indem Modelle verschiedener Haushalte adaptiv kombiniert werden. Ziel ist es, Modelle zu nutzen, die bereits für verschiedene Gebäude trainiert wurden (für die ausreichend Daten vorliegen), um die Vorhersagegenauigkeit in Gebäuden ohne ausreichende Daten zu verbessern. Die vierte Technik (d) der auf kausaler Interferenz basierenden Lastprognose schließlich versucht, verborgene Variablen zu erlernen, die dem Lastverbrauch entsprechen (d. h. Muster im Lastprofil und seinen Übergängen im Laufe der Zeit). Ziel ist es, Muster in den Daten zu erkennen (z. B. aufgrund von spezifischem Nutzerverhalten oder Wetterbedingungen) und Modelle zu trainieren, die auf solchen Mustern basieren.

Die Methoden (a)-(b)-(c) können als Variationen der Transfer-Learning-Prognose betrachtet werden, die Task 4.4 entspricht, und die Methoden von (d) entsprechen Task 4.2 und Task 4.3. Diese Methoden können auch verwendet werden, um Modelle zwischen Haushalten auszutauschen, da ein besser trainiertes Modell eines Gebäudes mit mehr historischen Daten die Vorhersageleistung eines mit weniger Daten trainierten Modells in einem neuen Gebäude verbessern kann.

a. Adaptive Modellumschaltung

Wie zu erwarten ist, schneiden nicht alle Modelle unter den gegebenen Bedingungen gut ab. Außerdem benötigen bestimmte Modelle möglicherweise Daten mit einem ausreichend großen Zeithorizont, um richtig trainiert zu werden. Infolgedessen kann es sein, dass zu einem bestimmten Zeitpunkt nur eine Teilmenge der Modelle gut abschneidet. Um die unterschiedlichen Fähigkeiten der betrachteten Modelle besser zu nutzen und Modelle zu verwenden, die derzeit besser abschneiden, wird in diesem Abschnitt ein adaptiver Modellwechsel eingeführt.

Gierige Auswahl vom Vortag (AMSG1). Die Auswahlmethode von AMSG1 besagt einfach, dass das Modell verwendet wird, das gestern besser abgeschnitten hat. Am Ende jedes Tages $d - 1$ wird jedes verfügbare Basismodell der Standardmodelle auf der Grundlage seines RMSE über den aktuellen Kalendertag bewertet. Das Modell mit dem niedrigsten RMSE über den Tag $d - 1$ wird für die Erstellung der Prognosen des Tages d ausgewählt.

Gierige Auswahl aus den letzten N Tagen (AMSGN). Es kommt häufig vor, dass ein Modell über einen Zeitraum von einem Tag gut abschneidet, diese gute Leistung aber nicht über größere Zeiträume beibehält. Um einen unnötig häufigen Wechsel zwischen den Modellen in AMSG1 zu vermeiden, schlägt AMSGN eine leicht aktualisierte gierige Auswahlstrategie vor, bei der das Basismodell mit dem kleinsten durchschnittlichen Tages-RMSE über einen Zeitraum von N vorangegangenen Tagen ausgewählt wird. Wir betrachten insbesondere $N = 10$ Tage.

MLP-basierte Auswahl (AMSMLP)

Ein neuronales MLP-Netz wird verwendet, um das Klassifizierungsproblem der Auswahl des besten Modells für die Erstellung der Prognosen für den nächsten Tag zu lösen. Die Anzahl der Eingänge und die Anzahl der Ausgänge des Netzes entsprechen der Anzahl der Standardmodelle. Jeder der MLP-Eingänge wird mit dem am Tag $d - 1$ gemessenen RMSE-Wert des entsprechenden Modells gespeist. Das Modell, dessen Ausgang auf 1 gesetzt wird, wird ausgewählt, um die Prognosen für den nächsten Tag d zu erstellen, während die anderen Ausgänge auf 0 gesetzt werden.

b. Ensemble-Modellierung

Es ist zu erwarten, dass jedes der Standardmodelle unter verschiedenen Betriebsbedingungen und/oder bei unterschiedlichem Verhalten der Bewohner unterschiedlich abschneiden kann. Außerdem kann jedes Modell unterschiedliche Trainingszeiten aufweisen (z. B. kann das SPNN-Modell im Vergleich zum SPR-Modell längere Trainingszeiten erfordern), was zu Schwankungen in der Leistung während des Simulationszeitraums führen kann. Um die unterschiedlichen Fähigkeiten der betrachteten Modelle besser auszunutzen und Modelle zu verwenden, die derzeit besser abschneiden, stellen wir in diesem Abschnitt mehrere Möglichkeiten zur Erzeugung von Ensemble-Modellen vor, d. h. von Mischungen aus einer Reihe von Basismodellen. In diesem Papier entsprechen die betrachteten Basismodelle den in den vorherigen Abschnitten diskutierten Standardmodellen (nämlich N-days, N-same-days, HW, SARIMA, PAR, SPR, SPNN).

Ensemblemodelle mit linearer Regression (EMLR). Dieses Ensemble-Modell kombiniert die Basismodelle durch Einführung einer linearen Regression, wobei die Regressoren die Ergebnisse der Basismodelle sind. Bezeichnet F die Menge der Basismodelle, so entspricht das Ensemble-Modell einem gemischten Modell der Form

$$\hat{y}_d^{EMLR}(t) = \sum_{f \in F} w_f(t) \hat{y}_d^f(t)$$

für einige unbekannte Parameter $w_f(t)$, die identifiziert werden müssen. Zur Berechnung der Gewichte, die diesen Regressoren zugewiesen werden, verwenden wir RLS, wie im **Error! Reference source not found.**

Ensemblemodelle mit MLP (EMMLP). Diese Klasse von Ensemble-Modellen stellt eine gewichtete Kombination der Ergebnisse der Basismodelle dar, ähnlich wie bei den EMLR-Modellen. Der einzige Unterschied besteht darin, dass die Gewichte mithilfe einer nichtlinearen Architektur des MLP berechnet werden.

Ensemble-Modelle mit gewichteten Durchschnittsprognostikern (EMWAF). Die Ensemble-Modellierungsstrategien von EMLR und EMMLP beruhen auf der Berechnung einer Kombination der Basisprognosemodelle, die im Hinblick auf ihre früheren Leistungen optimal ist. Solche Ensembles bieten jedoch keine Garantien in Bezug auf die langfristige Leistung. Aus diesem Grund betrachten wir einen exponentiell gewichteten Durchschnittsprognostiker [9], der zur Familie der expertenbasierten Prognosemodelle gehört. In diesem Zusammenhang wird jedes Modell als Experte $f = 1, \dots, m$ betrachtet

(was eine Aufzählung der Basismodelle in F ist), von denen jedes seine eigene Zeitreihenprognose für den nächsten Tag liefert. $Y_d = \{y_d(t)\}_{t=1,\dots,n}$ sei die Folge von Lastmessungen über den Tag d ,

$$\hat{Y}_d^f = \{\hat{y}_d^f(t)\}_{t=1,\dots,n}$$

die Abfolge der Prognosen des Modells/Experten f für den nächsten Tag und $\hat{P}_d = \{\hat{p}_d(t)\}_{t=1,\dots,n}$ die Abfolge der Prognosen des ausgewählten Prognostikers (die im Allgemeinen eine gewichtete Kombination der Prognosen der verfügbaren Experten sein kann).

Um die Leistung der Vorhersagemodelle zu bewerten, müssen wir auch den Begriff des Vorhersageverlusts über einen Zeitraum von einem Tag einführen, der wie folgt definiert ist

$$l(\hat{P}_d, Y_d) = \frac{|\hat{P}_d - Y_d|_2^2}{n(\varphi + 1)^2 |Y_d|_\infty^2}$$

wobei φ eine ganzzahlige Konstante ist, und wir definieren

$$|\hat{P}_d - Y_d|_2^2 = \sum_{t=1}^n (\hat{p}_d(t) - y_d(t))^2$$

und $|Y_d|_\infty = \max_{t=1,\dots,n} y_d(t)$. Man beachte, dass, wenn wir φ hinreichend groß setzen, wir garantieren, dass die Verlustfunktion l innerhalb von $[0,1]$ für alle d beschränkt ist. Analog dazu können wir die Vorhersageverluste der einzelnen Prognostiker als $l(\hat{Y}_d^f, Y_d)$ definieren. Schließlich bezeichnen wir $L_N = \sum_{d=1}^N l(\hat{P}_d, Y_d)$ als die kumulativen Verluste des gewichteten Prognostikers über einen Zeitraum von N Tagen und $L_{f,N} = \sum_{d=1}^N l(\hat{Y}_d^f, Y_d)$ als die kumulativen Verluste der einzelnen Prognostiker unabhängig. Das kumulative Bedauern für die Nichtauswahl von Prognostiker f wäre dann

$$R_{f,N} = L_N - L_{f,N}$$

Mit anderen Worten, ein positiv bewerteter kumulativer Bedauernswert stellt die Verbesserung der Genauigkeit dar, die wir durch den Einsatz von Prognostiker f weiter erreichen könnten.

Nach der gewichteten Durchschnittsprognose ist die Prognose für den nächsten Tag d gegeben durch:

$$\hat{p}_d(t) = \frac{\sum_{f=1}^m e^{-\theta L_{f,d-1}} \hat{y}_d^f(t)}{\sum_{f=1}^m e^{-\theta L_{f,d-1}}}$$

wobei θ eine positive Konstante ist, die die Trägheit bei Modelländerungen erfasst. Wir können auch die entsprechenden Gewichte, die der gewichtete Prognostiker dem f -ten Modell am Tag d zuweist, als $w_{f,d-1}$, $f = 1, \dots, m$, einführen, was zu folgenden Ergebnissen führt

$$\hat{p}_{d,t} = \sum_{f=1}^m w_{f,d-1} \hat{y}_d^f(t)$$

Beachten Sie, dass der gewichtete Durchschnittsprognostiker nicht sofort zu einem anderen Modell f wechselt, selbst wenn der kumulative Verlust dieses Modells kleiner wird als der kumulative Verlust eines anderen Modells. Stattdessen wird die Gewichtung allmählich erhöht (mit einer Rate, die durch den Parameter θ bestimmt wird). Bei einem solchen gewichteten Prognosemodell ist also ein schneller Wechsel zwischen den Modellen nicht mehr möglich, so dass die Modelle ausgewählt werden, die langfristig besser abschneiden.

c. Transfer-Learning-basierte Lastvorhersage und Ensemble-Modellierung

Die meisten Prognosemodelle benötigen ausreichend Daten (über mehrere Monate), um gut zu trainieren. Wenn für ein Wohngebäude nur eine begrenzte Menge an Daten zur Verfügung steht, werden die meisten Prognosemodelle nicht gut funktionieren. In diesem Fall können Persistenzmodelle eine Lösung bieten, allerdings kann die Genauigkeit solcher Modelle ebenfalls begrenzt sein, da sie sich nur auf eine begrenzte Anzahl von vergangenen Tagen stützen. Aus diesem Grund untersuchen wir in diesem Abschnitt die Möglichkeit, dass Prognosemodelle, die in Daten verschiedener, aber ähnlicher Wohngebäude (so genannte "train"-Gebäude/Datensätze) trainiert wurden, zur Verbesserung der Prognoseleistung in Gebäuden mit begrenzten Daten (so genannte "test"-Gebäude/Datensätze) verwendet werden. Die Integration der Zug- und Testdatensätze kann mithilfe eines gewichteten Prognosemodells erfolgen [10]. Da ein gewichteter Durchschnittsprognostiker mehrere Prognostiker/Experten berücksichtigen kann, werden wir ihn zur Lösung dieser Aufgabe heranziehen.

In unserer Untersuchung stellen die Experten oder Prognostiker des gewichteten Durchschnittsprognostikers alle verfügbaren Modelle dar, die anhand der Zug- und Testgebäude/Datensätze trainiert wurden. Diese Modelle liefern Prognosen für den nächsten Tag für das Testwohngebäude, und der gewichtete Durchschnittsprognostiker lernt die optimale Kombination dieser Modelle. Wenn also ein Modell eines Trainingsgebäudes in Kombination mit dem Testmodell die Vorhersagegenauigkeit verbessern kann, wird beiden Modellen ein positives Gewicht zugewiesen. Genauer gesagt wird der gewichtete Durchschnittsprognostiker in ähnlicher Weise definiert wie in Abschnitt EMWAF beschrieben, wobei die Prognostiker $f = 1, \dots, m$ Modelle darstellen, die in den Zug- und Testwohngebäuden trainiert wurden. Alle Modelle entsprechen der PAR-Modellarchitektur.

d. Auf Kausalinterferenz basierende Lastprognose und Ensemble-Modellierung

Alle zuvor besprochenen Standardmodelle werden anhand des kompletten Satzes historischer Lastverbrauchsdaten über mehrere Monate oder sogar Jahre trainiert. Infolgedessen erfassen all diese Modelle das durchschnittliche Verhalten des Stromverbrauchs über große Zeiträume hinweg. Daher ist die Vorhersage von Lastspitzen oder schnellen Schwankungen recht schwierig, was die Prognoseleistung erheblich einschränkt. Wenn beispielsweise der Stromverbrauch in den Morgenstunden einem anderen Profil/Muster folgt als in den Abendstunden, dann wird ein Modell, das mit allen Daten trainiert wurde, versuchen, den Durchschnitt aus beiden Verhaltensweisen zu bilden. Wenn stattdessen verschiedene Modelle auf unterschiedliche Bedingungen angewandt werden, dann sollten wir erwarten, dass genauere Vorhersagen abgeleitet werden können.

Außerdem können bestimmte Muster im Lastverbrauch anderen Mustern folgen. Wenn z. B. mehrere Personen die elektrischen Geräte zu unterschiedlichen Tageszeiten benutzen, beeinflusst ihr Zeitplan die Abfolge der beobachteten Muster im Lastverbrauch. Insbesondere können Lastverbrauchsprofile in bestimmten Sequenzen auftreten, die sich je nach Art des Tages (z. B. Wochenenden gegenüber Werktagen) oder anderen exogenen Faktoren (z. B. Wetterbedingungen) ändern können. Ein solches Beispiel für Muster, die von exogenen Bedingungen beeinflusst werden, ist in Abbildung 11 dargestellt. Man beachte, dass die Stromlast bis 08:00 Uhr nahe Null liegt und dann bis 15:00 Uhr auf etwa 3 kWh pro 15-Minuten-Intervall ansteigt. Nach 15:00 Uhr folgt die Stromlast einem anderen Profil mit einem durchschnittlich niedrigeren Verbrauch. Solche Änderungen des Lastprofils während des Tages können auf exogene Faktoren zurückzuführen sein, die von den Bewohnern des Gebäudes berücksichtigt werden (z. B. wird um ca. 08:00 Uhr die PV-Produktion verfügbar und hält bis ca. 15:00 Uhr an, was dem recht

hohen Lastprofil ziemlich genau folgt), oder es könnte sich um ein anhaltendes Verhalten über mehrere Tage in Folge handeln (z. B. im Rahmen der Zeitpläne der Bewohner).




Abbildung 11 Beispiele für durch exogene Faktoren beeinflusste Muster des Stromverbrauchs

Um solche Zustände/Muster im Stromverbrauch sowie die Abfolge solcher Muster zu erkennen, haben wir eine verallgemeinerte Input-Output Hidden-Markov Model (IOHMM)-Architektur entwickelt.[11] Eine schematische Darstellung der vorgeschlagenen Architektur ist in Abbildung 12 zu sehen. Gemäß dieser Architektur wird jeder Tag d in eine Reihe von vordefinierten Zeitintervallen unterteilt, die mit $i = 1, \dots, N$ bezeichnet werden. Jedes Zeitintervall t_i^d ist durch einen verborgenen (latenten) Zustand X_i gekennzeichnet, der unbekannte (nicht gemessene) Bedingungen darstellt, die den Lastverbrauch beeinflussen. Solche unbekannten Bedingungen können dem Zeitplan der Bewohner des Haushalts entsprechen, der einen indirekten Einfluss auf die Art der verwendeten elektrischen Geräte hat. Solche Bedingungen können auch von verschiedenen exogenen Faktoren beeinflusst werden, wie z. B. der Tageszeit oder den Wetterbedingungen, die in den Informationsparametern $I(d)$ zusammengefasst sind. Darüber hinaus können die unbekannten Bedingungen/Muster, die beim Lastverbrauch beobachtet werden, auch durch die Richtlinien eines Energiemanagementsystems oder einen Reglerausgang $U_i(t)$ beeinflusst werden. Diese Bedingungen haben einen direkten Einfluss auf die Lastverbrauchsmessungen, die durch Y_i angegeben werden.




Abbildung 12 Zerlegung eines jeden Tages in Zeitintervalle, die jeweils unterschiedlichen versteckten Bedingungen unterliegen und durch Informationsparameter und Steuersignale beeinflusst werden.

Das in Abbildung 12 dargestellte IOHMM-Modell versucht, dynamische Abhängigkeiten zwischen Mustern zu erfassen. Insbesondere kann es der Fall sein, dass bestimmte Bedingungen/Mustern erst nach anderen spezifischen Bedingungen/Mustern auftreten. Zum Beispiel wird der aktuelle Zeitplan der Bewohner des Gebäudes im aktuellen Zeitintervall i wesentlich durch den Zeitplan im vorherigen Zeitintervall beeinflusst $i - 1$. Wenn wir die Notation von Abbildung 12 verwenden, bedeutet dies, dass der verborgene Zustand des Zeitintervalls $i = 2$ des Tages $d + 1$, bezeichnet als $X_2(t_2^{d+1})$, durch den verborgenen Zustand des vorherigen Zeitintervalls desselben Tages $X_1(t_1^{d+1})$ beeinflusst werden kann (Markov-Eigenschaft).

Zusätzlich zu den dynamischen Abhängigkeiten von den Bedingungen/Mustern des vorangegangenen Zeitintervalls können auch zusätzliche Abhängigkeiten von den Bedingungen/Mustern desselben Intervalls am Vortag bestehen. Solche Abhängigkeiten sind beim Lastverbrauch recht häufig, und wir haben sie bereits im Zusammenhang mit den Persistenzmodellen N-days und N-same-days ausgenutzt. Dies bedeutet, dass der Zustand $X_2(t_2^{d+1})$ sowohl vom Zustand des vorangegangenen Zeitintervalls, $X_1(t_1^{d+1})$, als auch vom Zustand des gleichen Zeitintervalls des Vortages $X_2(t_2^d)$ abhängt. Im Wesentlichen gehen wir hier implizit davon aus, dass der Lastverbrauch einem markovianischen Verhalten folgt, bei dem die Bedingungen des vorangegangenen Zeitintervalls und des Vortages den größten Einfluss haben. Diese Abhängigkeiten sind in Abbildung 13 noch deutlicher dargestellt.




Abbildung 13 IOHMM-Struktur und markovsche Abhängigkeiten des Lastverbrauchs in jedem Zeitintervall.

Dieser Modellierungsrahmen ist geeignet, Muster im Stromverbrauch zu erfassen, kann aber indirekt auch Muster im Nutzerverhalten erfassen. Wenn beispielsweise bestimmte Nutzer bestimmte Geräte an bestimmten Tagen/Stunden verwenden, wird das auf diesen Tag spezialisierte Modell (da der Tag ein Input ist) angepasst, um das Verhalten dieser Nutzer zu erfassen. Für ein solches Modell können auch zusätzliche Eingaben in Betracht gezogen werden. Wenn die Eingabe zum Beispiel der Frage entspricht, ob der Nutzer einen Optimierungsvorschlag vom Optimierer (oder Aggregator) erhalten hat, dann können alle Änderungen im Verhalten des Nutzers während der nächsten Stunden von einem solchen Modell erfasst werden. Mit einem solchen Ansatz lassen sich daher sowohl die Herausforderungen von Aufgabe 4.2 als auch von Aufgabe 4.3 bewältigen.

2.4 AP5: Smart Energy Service mit integrierter Datenqualitätsüberwachung und -verbesserung

Das Projekt Serve-U entwickelt und validiert eine Energieeinsatzoptimierungsplattform, welche es Energie-Gemeinschaften mit minimalem technischem und finanziellem Aufwand ermöglicht, die Nutzung erneuerbarer Energieträger flexibel und bedarfsoptimiert zu steuern. Zu diesem Zweck erfolgt die Einbindung hochauflösender meteorologischer Erzeugungsabschätzung, sowie selbstlernender Verbrauchsprognosen in ein Energieoptimierungsmodell (Serve-U). Ein hohes Maß an Skalierbarkeit wird durch den Fokus auf verfügbarer – teils auf offenen Standards basierende - Erzeugungs-, Last- (Smart-Meter- und Wechselrichterdaten) und Marktdaten erreicht. Ziel ist es das wirtschaftliche und ökologische Potential eines derartigen Low-Cost-Optimierungs-Ansatzes für Energiegemeinschaften unter Berücksichtigung Nutzer:innen-spezifischer Aspekte zu ermitteln.

2.4.1 Server Infrastruktur, Datenbank und relevante Schnittstellen

In den folgenden Punkten werden die Kernkomponenten des Systems überblicksmäßig beschrieben. Hierbei liegt der Fokus auf den Grundgedanken hinter der Komponente, sowie auf der Interaktion mit anderen Komponenten. Abbildung 14 beschreibt die Komponenten in grafischer Form.

- **Datenplattform mit Datenbank**

Das zentrale Datenspeichermedium der Datenplattform ist eine relationale Datenbank, die auf Basis der fachliche Anforderungsspezifikation der Expert:innen umgesetzt wurde. Die Datenplattform dient als Bindeglied zwischen den einzelnen Komponenten und der REST-Schnittstelle für die App.

- **Datenlieferant:innen**

Die Art und Qualität der Daten beeinflussen nicht nur das User Interface (UI), bzw. die User Experience (UX) der App. Im Vorfeld wurden historische Daten (Erzeugungs- und Verbrauchsdaten, sowie Wetterdaten) geliefert, um die Konzipierung anhand tatsächlicher Werte vornehmen zu können.

- **Lieferant:innen von Erzeugungs- und Verbrauchsdaten**

Erzeugungsdaten und Verbrauchsdaten werden direkt in das System geliefert und verarbeitet.

- **Lieferanten von Wetterdaten**

Aktuell gemessene Wetterdaten und Wetterprognosen werden angeliefert und verarbeitet.

- **Data Cleaning Service**

Der Service übernimmt zwei wesentliche Funktionen, einerseits die Überprüfung der Daten auf Plausibilität, andererseits wird eine Warnung bei Unstimmigkeiten ausgegeben.

- **Prognose-Algorithmus für Erzeugung und Verbrauch**

Der Algorithmus wird basierend auf historischen Energie- und Wetterdaten trainiert. Durch den Algorithmus soll, durch die tagesaktuell angelieferten Wettervorhersagen, eine treffende Erzeugungs- und Verbrauchsprognose generiert werden. Diese Prognosen sollen sowohl für Haushalte als auch für Gruppen erstellt werden.

- **Empfehlungsalgorithmus für Lastverschiebung**

Die angestrebte Lastverschiebung, also eine Anpassung des Verhaltens wann, wodurch Energie verbraucht wird, soll durch Empfehlungen an Nutzer:innen, basierend auf den vorhandenen Geräten und der Prognosedaten, erreicht werden.

- **App für Endbenutzer:innen**

Die Oberfläche der Applikation für die Endbenutzer:innen visualisiert unterschiedliche Daten. Es werden Energieverbrauch und Erzeugung des eigenen Haushalts und der gesamten Gruppe dargestellt, ebenso der prognostizierte künftige Verbrauch und Erzeugung des eigenen Haushalts und der gesamten Gruppe. Zusätzlich werden auch generierte Vorschläge mit Sparpotential angezeigt. Die Vorschläge und aktuelle Neuigkeiten, werden den Nutzer:innen als individuelle Benachrichtigungen zugestellt.

Es wurden folgende Software-Infrastruktur-Services verwendet, um die Energie Service Plattform umzusetzen. Hierbei handelt es sich ausschließlich um Open Source Software Lösungen.

- **RabbitMQ**

RabbitMQ ist ein State-of-the-Art Message Broker, welcher den Nachrichtenaustausch zwischen den unterschiedlichen Komponenten ermöglicht. Die Kommunikation ist asynchron und zeichnet sich durch die einfache Skalier- und Erweiterbarkeit aus.

- **S3 Service (Minio)**

Das S3 Service dient als Speicherservice, den Lieferant:innen für das Ablegen von Daten nutzen können. Dieser Service ist „cloud enabled“, das heißt, es kann jederzeit auf andere, auch cloud-basierte Umgebungen migriert werden. S3 wird in Serve-U zur Archivierung von Rohdaten vor dem Import in die Datenbank genutzt.

- **Datenbank (PostgreSQL)**

Bei der Datenbank wird PostgreSQL, sowie deren Timescale Erweiterung für Time-Series Daten genutzt. In der Datenbank werden zeitsensitive Daten abgespeichert, die als Grundlage für die Prognosealgorithmen dienen.

- **Grafana**

Grafana ist ein Visualisierungstool für Daten, welches auch für Analysezwecke verwendet wird. Durch die Einbindung von Grafana werden die Daten aus der Datenbank in der Anwendung visualisiert.

Kommunikation zwischen den Komponenten

Das Kommunikationskonzept der Komponenten basiert auf der allgemeinen Kommunikation via Message Queues mithilfe der RabbitMQ Software (sh. Abbildung 14). Bei diesem Nachrichtenformat wird auf eine UTF-8 Codierung, JSON Serialisierung und eine Vordefinition des Formats für die einzelnen Komponenten, gesetzt. Lediglich das API Backend der Datenplattform und das Data Cleaning Service haben direkten Zugriff auf die Datenbank, andere Komponenten erhalten die Daten via RabbitMQ.




Abbildung 14 Überblick über die Energy Service Datenplattform Architektur

Nach dem Hochladen von neuen Datensätzen durch Lieferanten müssen die folgenden beiden Anpassungen vorgenommen werden: (1) einerseits muss der S3 Service eine Benachrichtigung über den Erhalt einer Datei via RabbitMQ senden, (2) andererseits muss das Datenschema für jeden Datensatz fixiert werden.

Die Web-UI und App sind mittels einer vom Backend bereitgestellten REST Schnittstelle angebunden.

Datenfluss

Wie in *Abbildung 15* dargestellt kann der Datenfluss in mehrere, voneinander abhängige, Schritte zerlegt werden.




Abbildung 15 Datenfluss in der Applikation

Im ersten Schritt werden Daten folgende von Lieferant:innen bereitgestellt:

- Stromverbrauch

- Stromerzeugung
- Gesammelte Meteorologiedaten

Im zweiten Schritt werden diese Rohdaten in das korrekte Schema überführt und in der Datenbank gespeichert. Im dritten Schritt werden Daten an das Data Cleaning Service gesendet, um die Datenqualität festzustellen. Nach einer erfolgreichen Ermittlung der Datenqualität kommt es zur Speicherung der Daten. Nun können die aufbereiteten Daten für die Erzeugungs- und Lastprognose für Haushalte und Gruppen genutzt werden. Die meteorologischen Daten werden in Verbindung mit dem aktuellen Verbrauchs- und Erzeugungsdaten als Ausgangspunkt für die Prognose genutzt. Die berechnete Prognose dient dann im nächsten Schritt zur Ableitung von Handlungsempfehlungen für die Endbenutzer:innen. Explizit werden hier auch Parameter, wie die Flexibilität in Haushalts(Geräten) und die Erzeugung der Gruppe/des Haushalts, miteinbezogen.

Die erzeugten Vorschläge, annotiert mit möglichem Energiesparpotential, werden aufgezeichnet und am Ende in der Benutzeroberfläche der App dargestellt.

Datenspeicherung und Datenmodell

Die Daten werden vereinheitlicht in die Datenbank importiert und die Rohdaten werden in dem S3 Speicher für spätere Analysezwecke archiviert. Sowohl die berechneten Prognosen als auch die daraus abgeleiteten Handlungsempfehlungen werden in der Datenbank persistiert. Des Weiteren wird in der Datenbank gespeichert, ob Nutzer:innen einen Vorschlag angenommen oder abgelehnt haben. Dies ermöglicht dynamische Anpassungen des Algorithmus. Rudimentäre Aktivitätsdaten von Nutzer:innen werden ebenfalls für spätere Analysen gespeichert. Log-Daten werden gespeichert, um die Fehlerbehebung zu vereinfachen.

Abbildung 16 zeigt das Datenmodell, welches zur Speicherung der oben beschriebenen Daten in der PostgreSQL Datenbank entwickelt wurde.




Abbildung 16: Das Datenmodell der Energy Service Platform

Datenqualitätsregeln und -metriken

Um Datenqualität als solches messbar zu machen, werden üblicherweise sogenannte Metriken, bzw. Dimensionen eingesetzt. Ziel dieser Metriken ist es, ein aufgabenunabhängiges Bild über die Daten zu beschreiben. Solche Metriken können dementsprechend auf beliebige Datensets angewandt werden, um

so vergleichbare Aussagen über sie treffen zu können. Folgende Metriken wurde ausgewählt, da sie für die von Partner definierten Anwendungsfälle den besten Effekt haben: (1) Vollständigkeit, (2) Konsistenz, (3) Pünktlichkeit. In den folgenden Absätzen werden die ausgewählten Metriken beschrieben.

Vollständigkeit

Vollständigkeit beschreibt das Ausmaß, in welchem sich die verfügbaren Daten befinden. Man geht von einem Schema aus, dem die Daten entsprechen müssen. Das Schema kann zum einem das Datenmodell sein, dem die Daten folgen müssen, zum anderen aber auch ein „Gold Standard“, der alle möglichen Datensätze im Datenset beinhaltet. Letzteres ist im praktischen Einsatz de-facto unmöglich. Wir gehen von einem einfachen Datenschema aus, das auf Basis der vordefinierten Use-Cases definiert wurde. Dieses Schema beschreibt die Art der Datenkomponenten in Form eines Datentyps und teilweise durch einen vordefinierten Standardwert. Wir definieren daher die Vollständigkeit als das Vorhandensein aller Komponenten des Datensatzes in Referenz zu dem definierten Datenschema. Standardwerte werden hier dem Fehlen des Wertes gleichgesetzt (Ehrlinger, Werth, & Wöß, Quelle: A Data Quality Assessment Tool for Integrated Information Systems, 2018).

Konsistenz

Unter Konsistenz versteht man, dass die Daten dem erwarteten Verlauf entsprechen. Dieser Verlauf kann durch semantische Regeln umschrieben werden. Im weitesten Sinne kann hierunter auch die Ausreißer Erkennung unter Zuhilfenahme von statistischen Methoden fallen, indem die Standardabweichung aktueller Werte über die Zeit hinweg immer in einem vordefinierten Bereich liegt. Üblicherweise muss die Konsistenz über heterogene Datenquellen berechnet werden. (Ehrlinger & Wöß, A Survey of Data Quality Measurement and Monitoring Tools, 2022)

Ein Beispiel für eine solche semantische Regel über mehrere Datenquellen hinweg ist: „Der Wert des Ladezustands im Bereich $[t_0-t_n]$ korreliert laut Korrelationskoeffizient >0.8 mit dem gleichen Bereich $[t_0-t_n]$ der aktuellen Energieproduktion des Haushalts.“

Pünktlichkeit

Wir definieren Pünktlichkeit als das Maß, inwieweit die Daten ausreichend aktuell sind, aber auch, ob Daten zeitlich konstant verarbeitet werden. Hierbei gehen wir von einem fix definierten Zeitfenster aus, in dem einzelne Datensätze im System ankommen müssen. Die Differenz zwischen dem definierten Ziel und der Ankunftszeit des Datensatzes muss hier möglichst null sein. Man beachte, dass auch ein verfrühtes Ankommen der Daten nicht positiv im Sinne der Datenqualität ist. Ziel der Metrik ist es, eine möglichst konstante Datenrate zu erreichen, sodass auch heterogene Datenquellen einheitlich analysiert werden können. (Pipinio, Lee, & Wang, 2002)

Eine variable Datenrate kann auf mehrere Probleme im Gesamtsystem hindeuten, unter anderem:

- Die datenproduzierende Komponente ist in einem inkonsistenten Zustand, durch bspw. niedrige Energiezufuhr oder Verschleiß
- Das Datenintegrationssystem ist überlastet
- Es existieren Fehler beim Laden der Rohdaten
- Ein Update hat angenommene Parameter verändert

Datenqualitätsüberwachung

Die Datenqualitätsregeln und -metriken bilden die Grundlage für die Datenqualitätsüberwachung. Abbildung 17 zeigt eine Übersicht über das Datenqualitätsüberwachungssystem. Als Input werden asynchrone Datenströme auf Basis von RabbitMQ erwartet. Die benötigte Infrastruktur wurde in Server Infrastruktur, Datenbank und relevante Schnittstellen vorgestellt. Zusätzlich werden zusätzliche Persistenzkomponenten benötigt, die bspw. zum Zwischenspeichern von Aggregaten und dokumentieren von möglichen Datenqualitätsproblemen dienen (Ehrlinger & Wöß, 2017). Die folgenden Absätze beschreiben die einzelnen Komponenten, die für die Datenqualitätsüberwachung und potenziellen Verbesserung notwendig sind.

Collector

Datenqualitätsmessung auf einzelne, unabhängige Datensätze ist nicht zielführend (Azimi & Pahl, 2001). Hier kann keine eindeutige Aussage über komplexe Gegebenheiten des gesamten Datenstroms getätigt werden, nur ob Daten vorhanden sind (Ehrlinger, Werth, & Wöß, 2018). Da auch nicht der gesamte Datenstrom im Speicher mitgeführt werden kann, müssen die einzelnen Datensätze aggregiert werden (Boniol, 2021). Mithilfe der Sliding Window Methode wird ein Ausschnitt des Datenstroms im Speicher gehalten, der immer die aktuellen Datensätze beinhaltet. Bei einem neuen Datensatz wird der bisherige Älteste ausgeschieden. Ein Collector wendet diese Methode immer auf einem Datenstrom an legt so die Grundlage für die Datenqualitätsüberwachung in den nächsten Komponenten.

Beispielimplementierungen für solche Collectors wurden für die Datenströme des Ladezustands der Batterien, die Energiezufuhr zum Gesamtnetz als auch den Verbrauch eines Haushalts bereitgestellt.




Abbildung 17 Überblick über Datenqualitätsüberwachung- und Verbesserung System

Detector

Ein Detector untersucht ein aufbereitetes Sliding Window nach möglichen anomalen Sequenzen. Eine anomale Sequenz ist ein Sliding Window, dass nicht dem Datenqualitätsstandard entspricht, bspw. fehlen Datensätze, statistische Ausreißer, die Datenkonsistenz ist nicht gegeben etc. (Boniol, 2021). Die genaue

Definition einer anomalen Sequenz ist hier abhängig von der Implementierung des jeweiligen Detectors. Das Ergebnis eines Detectors ist zusammengefasst ein annotiertes Sliding Window, falls eine anomale Sequenz laut Implementierung gefunden wurde. Die eigentliche Analyse wird in einer späteren Komponente gehandhabt.

Analyzer

Bei Erkennung einer anomalen Sequenz durch einen Detector wird das betroffene Sliding Window von einem, oder mehreren Analyzern untersucht. Analyzer nutzen gesammeltes Domänenwissen, um mögliche Gründe für das Auftreten dieser anomalen Sequenz zu finden. Dieses Wissen entspricht Regeln, die in einer Knowledge Datenbank gespeichert ist. Beispiele für solche Regeln sind:

- Änderung des Datentyps kann auf Software-Update hindeuten
- Zeitlich unregelmäßige Datensätze können auf Überlastung des Datenintegrationssystems hindeuten
- Eine schleichende Änderung von korrelierende Datenströmen kann auf Context Drift in den Datenquellen hindeuten

Ein Analyzer bietet also eine mögliche Erklärung für die anomale Datensequenz in dem aktuellen Sliding Window.

Measurement Suggestor

Abhängig von der Konfidenz der bisherigen Datenqualitätsmessung können, typische, oft erkannte Datenqualitätsprobleme automatisch und ohne direkten Domänenexperten Input gelöst werden. Der Measurement Suggestor nutzt historische Lösungen auf bekannte Datenqualitätsprobleme, um mögliche Lösungen vorzuschlagen. Die Vorschläge müssen aktiv von einem Domänenexperten bestätigt werden, um keinen schleichenden Fehler in kritischen Datendomänen zu erlauben.

Cleanser

Diese Komponente ist eine optionale Möglichkeit zur Steuerung der Datenqualitätsverbesserung. Sie nutzen die Vorschläge der Measurement Suggestors, falls Domänenexperten sie erlauben. Jegliche Änderung an den Datensätzen wird explizit in einer Audit Datenbank mitgeführt, um potenzielle Fehlentscheidungen zu erkennen und längerfristig zu verhindern. Die Änderungen an den Datensätzen werden zurück an die Datenintegrationskomponente geleitet.

IT-Security-Maßnahmen

Um die Sicherheit von persönlichen Daten zu gewährleisten, werden Server ausschließlich von der FHOÖ bereitgestellt. Es werden explizit keine Cloud oder anderen Services von Drittanbietern verwendet. Die personenbezogenen Daten sind zusätzlich pseudonymisiert und werden ausschließlich verschlüsselt übertragen. Allgemeine Zugriffsrechte werden auf ein Minimum reduziert. Komponenten und Benutzer:innen haben nur auf notwendige Daten Zugriff.

2.4.2 Interface für den Endbenutzer

Personas

Im folgenden Abschnitt werden drei Nutzer:innengruppen vorgestellt, die für die Entwicklung des UIs und UX definiert wurden. Die Personas wurden im Rahmen eines Workshops nach dem Konzept des Empathy Mappings erstellt (Bruna, Williamson, Edson, & Tayana, 2015). Die Teilnehmer des Workshops waren vorwiegend Mitarbeiterinnen des Projekts Serve-U. Es ging darum ein grundlegendes Verständnis der

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Bedürfnisse der Nutzer:innen in Bezug auf die Applikation zu erhalten und entsprechende UI/UX Design Entwürfe zu erstellen. Aus den Nutzer:innengruppen wurden keine konkreten Anwendungspersonas entwickelt.

Produktnutzer:innen			
	Wohnung	Einfamilienhaus	EEG und BEG und Service An- bieter
	- ich kann meine Waschmaschine nicht in der Nacht einschalten - zu laut - in einer EG habe ich Zugang zu Energie von einer PV (mehr Möglichkeiten)	- ich bin flexibler (wenn ich eine PV habe) - ich brauche mehr Strom als in einer Wohnung - wenn ich meinen Energieverbrauch anpasse bzw. optimiere kann ich viel bewirken /einsparen - ich kann meine Waschmaschine auch in der Nacht einschalten (höre ich aus dem Keller nicht)	- ich hätte gern anonymisierte Nutzerdaten - bei Ausfällen - bei Problemen - um das Verhalten zu analysieren - dynamische Energiemodelle werden präferiert
think	- Wie soll ich Energie richtig nutzen? - Geiz ist geil! - Ich bin so super, weil ich in einer EG bin/eine PV habe. - Wer hängt die Wäsche auf wenn meine WM genau läuft - wenn keiner daheim ist (programmierbar) - Wann ist die Energie am Billigsten?		
say	- ich habe mir xy gespart weil ich in einer EG bin/ eine PV habe - ich möchte nachhaltig agieren - ich möchte Geld sparen - Warum machst du nicht mit? - Was kann ich machen? - Wo kann ich mich informieren? (EG, PV,...)		

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

	• Wieviel Aufwand ist das? • Vielleicht können die Kraftwerksreserven (nicht erneuerbare Energien) generell reduziert werden		
hear	• PV in EG rentiert sich schneller • wenn man zusammenhält, gewinnt man mehr! • man ist unabhängiger - weil Teil der benötigten Energie selber produziert wird • Das bringt doch nix! (des bissl wenn du das Licht ausschaltest ist auch schon egal!) • Das kann nicht funktionieren! • Zahlt sich das aus?	•	•
do	• Der Energieverbrauch wird bewusst reduziert • Ich schaue nach, was ich an Energie erzeugt habe • ich verbrauche die Energie bewusst Verbraucher timen - wie z.B. Waschmaschine einschalten oder Elektroauto laden • ich verringere meinen ökologischen Fußabdruck • ich hole Informationen ein bzw. recherchiere (sowohl potenzielle zukünftige Kund:innen als auch interessierte schon bestehende Kund:innen	•	•

2.5 AP6: Entwicklung des Systemoptimierungsmodells

In einem ersten Schritt wurde die Systematik des Zusammenspiels zwischen der Optimierung und der Lastprognose (AP4) geklärt. Dies war notwendig, da die Optimierung direkten Einfluss auf das Nutzer:innen-Verhalten und damit auf die Lastprognose hat und sich diese wiederum auf die Optimierung auswirken kann.

In enger Zusammenarbeit und Abstimmung mit den Arbeitspaketen 2, 3, 4 und 8 wurden die Anforderungen und Einschränkungen des den Optimierungsalgorithmus sowie das Optimierungsziel definiert, die verfügbaren Input-Daten festgestellt und in einem Lastenheft dokumentiert (Deliverable 6.1). Auf Basis des Lastenheftes wurde das Optimierungsmodell in MATLAB entwickelt, sodass es im Anschluss möglich war den Algorithmus in das Simulationsmodell sowie in die Validierungsumgebung (AP 7) Einzubinden.

Um das Konzept einer Validierung mit realen NutzerInnen innerhalb der Validierungsumgebungen zu unterziehen, mussten die Optimierungsergebnisse in text- oder grafikbasierte Handlungsanweisungen übersetzt werden. Methoden dafür wurden unter Abstimmung mit den Arbeitspaketen 2 und 5 entwickelt und implementiert.

Durch die Einwirkungen des Energy-Services auf das Verbrauchsprofil und den Gleichzeitigkeitsfaktor können erhebliche Lastspitzen (niedriger Stromtarif, keine PV-Leistung) bzw. -schwankungen (PV-Leistung bricht ein, Strompreis ändert sich) hervorgerufen werden. Um kritische Netzzustände zu vermeiden, wurden entsprechende Randbedingungen im Algorithmus implementiert.

Parallel zur Entwicklung des Optimierungsalgorithmus wurde eine simulative Testumgebung erstellt, welche ein beispielhaftes Energiesystem einer erneuerbaren Energiegemeinschaft abbildet. Das Simulationsmodell ist an die, im Projekt definierten Validierungsumgebungen angelehnt und versucht diese möglichst realitätsgetreu abzubilden, um realistische Testszenarien nachstellen zu können.

Um das Energy-Service Konzept und die entwickelten Methoden und Algorithmen (AP2, 3, 4, 5) einer Funktionsüberprüfung zu unterziehen, wurden realistische Testszenarien in der Simulationsumgebung getestet. Die Ergebnisse sollten zur Verbesserung, Validierung und Potentialabschätzung des vorgestellten Service-Konzeptes dienen.

2.5.1 Beschreibung des Optimierungsproblems

Es soll ein neuartiger Ansatz für die Optimierung des Betriebs von Energiegemeinschaften durch die Berechnung von individuellen day-ahead Lastverschiebungs-Empfehlungen für Teilnehmer gefunden werden. Die Empfehlungen sind auf Geräteebene und beziehen eine Modellierung für die Umsetzungswahrscheinlichkeit ein, welche im Falle von Menschen als Schnittstelle zwischen Regler und Gerät benötigt werden.

Demand Side Management (=Nachfragesteuerung) durch Lastverschiebung in einzelnen und mehreren Haushalten wurde bereits in der Vergangenheit eingehend untersucht. Sharda et al [12] haben festgestellt, dass lineare Programmierung (LP) und gemischt ganzzahlige lineare Programmierung (MILP) häufig für diesen Zweck zum Einsatz kommen und sich in mehreren Studien als schnell und zuverlässig herausgestellt haben. Im Projekt Serve-U soll ebenfalls auf einen auf MILP basierenden Algorithmus gesetzt werden. Neben den bereits erwähnten Vorteilen ist die Nachvollziehbarkeit der Ergebnisse ein wesentlicher Vorteil gegenüber anderen Optimierungsstrategien.

Die Struktur des linearen Problems ist in Abbildung 47 dargestellt, welche eine beispielhafte Energiegemeinschaft mit zwei Haushalten zeigt. Jeder Haushalt ist an das Versorgungsnetz angeschlossen und hat auch eine Verbindung zum Knoten "Community". Haushalt X ist ein Prosumer, der nicht nur aus dem Netz und der Gemeinschaft verbraucht, sondern auch zu bestimmten Zeiten überschüssigen Strom produziert, der dann innergemeinschaftlich genutzt werden kann. Das Feld "Community" stellt den virtuellen Knoten dar, an dem jeder Nutzer innerhalb der Gemeinschaft den überschüssigen Strom einspeist oder den von anderen Mitgliedern der Gemeinschaft bereitgestellten Strom verbraucht. Daraus ergibt sich die grundlegende Bedingung, dass die Summe aller Stromflüsse in einem Knoten gleich Null sein muss. Natürlich fungiert das "Grid" als "unbegrenzte" Stromquelle und -senke. Der Verkauf von Überschussstrom an den Strommarkt ist nur als Gemeinschaft möglich. Es ist rechtlich nicht vorgesehen, dass ein Haushalt, der Teil der Gemeinschaft ist, überschüssige Energie direkt an einen Stromversorger verkaufen kann. Eine weitere wichtige Einschränkung ist, dass jedes Mitglied (finanziell) besser abschneiden muss als ohne Gemeinschaft.

Die Tarife werden für die Berechnung so gewählt, dass eine Minimierung der Gesamtkosten innerhalb der Gemeinschaft eine Maximierung des Eigenverbrauchs und des Autarkiegrades bewirkt.




Abbildung 18: Schema einer Energiegemeinschaft mit zwei Haushalten (ein Prosumer, ein Consumer). Die Pfeile repräsentieren mögliche (virtuelle) Energieflüsse bzw. Geldflüsse im System.

2.5.2 Anforderungen an den Optimierungsalgorithmus

Im Folgenden sollen die Anforderungen an den Algorithmus zur Lösung des oberhalb beschriebenen Problems möglichst kompakt aufgelistet werden.

Optimierungsziel:

- Das Optimierungsziel ist aus Sicht des Algorithmus stets die **Minimierung der Gesamtkosten** der Energiegemeinschaft. Um in der Realität einen Fokus auf andere Kennwerte zu legen, kann die **Tarifstruktur** für den Optimierer entsprechend **angepasst** werden.
- Das Ergebnis soll dem Nutzer folgende Information bereitstellen: **Gerät** und **Einschaltzeit**

Vorgaben und Einschränkungen:

- **Nachvollziehbar:** Die abrechnungsrelevanten (nicht physikalischen) Stromflüsse sollen möglichst genau abgebildet werden.
- **Skalierbar:** Der Algorithmus soll für Energiegemeinschaften mit beliebig hoher Teilnehmerzahl anwendbar sein.
- **Flexibel:** Es sollen ohne größeren Aufwand beliebige Geräte-Lastprofile hinterlegt und ergänzt werden können.

- **Integriert:** Der Algorithmus soll mit der Serve-U Datenbank über eine RabbitMQ-Schnittstelle kommunizieren und im besten Fall in einem Docker-Container laufen.
- **Vorteilhaft:** Kein Teilnehmer / keine Teilnehmerin soll durch die Optimierung bzw. Lastverschiebung Nachteile erfahren.

Die genannten Anforderungen stellen die Grundpfeiler für die Implementierung des Optimierungsalgorithmus im Serve-U Ökosystem dar.

2.5.3 Beschreibung des entwickelten Algorithmus

Die Kostenfunktion, welche sämtliche Stromkosten in der Energiegemeinschaft darstellen soll wurde wie folgt definiert:

$$c_{h,t} = P_{grid,h,t} \cdot tariff_{G2H} + P_{C_{to}H,h,t} \cdot tariff_{C2H} - P_{C_{from}H,h,t} \cdot tariff_{H2C} + P_{C_{to}Grid,h,t} \cdot (tariff_{H2C} - tariff_{C2G})$$

Dabei steht $c_{h,t}$ für die Stromkosten eines Haushalts h in einem Zeitschritt t , P ist die Energie in kWh pro Zeitschritt (in unserem Fall 15 Minuten), und der Tarif wird in €/kWh definiert. Der aus dem allgemeinen Stromnetz bezogene Strom wird durch P_{grid} dargestellt, die Energie, die von der Energiegemeinschaft (EC) an den jeweiligen Haushalt geliefert wird, durch $P_{C_{to}H}$, die überschüssige Energie des jeweiligen Haushalts durch $P_{C_{from}H}$, und die Einspeisung der EC ins Netz wird durch $P_{C_{to}Grid}$ repräsentiert. Die Tarife folgen einer ähnlichen Namenskonvention. Sie werden für jeden teilnehmenden Haushalt als gleich und über die Zeit als konstant angenommen. Sie werden so gewählt, dass der Eigenverbrauch maximiert und der Grad der Selbstversorgung erhöht wird.

Um die optimale Lastverschiebung für den Folgetag zu berechnen, werden Prognosen für den Energieverbrauch sowie die Energieproduktion für jeden teilnehmenden Haushalt und die gesamte Gemeinschaft verwendet. Wie unten gezeigt, wird die Summe der Stromkosten über alle Haushalte und über den nächsten Tag minimiert, unter Berücksichtigung der Einschränkungen.

$$\sum_t \sum_h c_{h,t} \rightarrow \min$$

Dabei stehen c für die Stromkosten, h für den Index des Haushalts und t für den jeweiligen Zeitstempel. Eine Einschränkung wurde eingeführt, um zu verhindern, dass einzelne Haushalte durch die empfohlenen Lastverschiebungen benachteiligt werden.

Um den verschiedenen Geräten, die sich für Lastverschiebungen in Haushalten eignen (Geschirrspüler, Waschmaschine, Trockner, Elektrofahrzeug, Wärmepumpe, Lastreduktion), Rechnung zu tragen, wurden Verbrauchsprofile für jeden Gerätetyp definiert. Da nicht bekannt ist, wann die betreffenden Lasten genutzt worden wären, müssen die Verbrauchsprofile der Geräte dem prognostizierten Lastprofil eines Haushalts hinzugefügt werden. Dies erhöht natürlich sowohl den Gesamtverbrauch als auch die Kosten eines Haushalts. Daher wird der Verbrauch linear um genau die Menge der durch die zusätzlichen Lastverschiebungsgeräte hinzugefügten Energie reduziert. Die folgenden Formeln zeigen diese Kompensation der zusätzlichen Last:

$$P_{load_{new},h,t} = P_{load,h,t} + P_{loadshift,h,t} - P_{comp,h,t}$$

Dabei ist $P_{load_{new},h,t}$ das prognostizierte Lastprofil $P_{load,h,t}$ (Energie pro Zeitschritt), das den Lastverschiebungsverbrauch $P_{loadshift,h,t}$ und die Kompensation $P_{comp,h,t}$ enthält.

Die Kompensation wird berechnet durch:

$$P_{comp,h,t} = P_{load,h,t} \cdot E_{loadshift,h} / E_{load,h}$$

wobei $E_{loadshift,h}$ die insgesamt verschobene Energie im Haushalt innerhalb des betrachteten Zeitraums ist und $E_{load,h}$ den gesamten prognostizierten Energieverbrauch des Haushalts im betrachteten Zeitraum darstellt.

Um sinnvolle und umsetzbare Lastverschiebungsempfehlungen zu erstellen, wurden die Haushalte zu den typischen Verfügbarkeiten (Tag und Uhrzeit) der vordefinierten Geräte befragt. Die Präferenzen der Nutzer wurden in das Optimierungsproblem einbezogen, indem eine Strafgebühr verhängt wurde, falls der Startzeitpunkt eines Geräts in einen Zeitraum mit schlechter Verfügbarkeit verschoben wird.

Das Ergebnis des Prognose- und Optimierungsprozesses ist das Gerät und die spezifische Einschaltzeit für jeden Haushalt. Diese Informationen werden dann weiterverarbeitet, in lesbaren Text umgewandelt und in einer mobilen oder webbasierten Anwendung präsentiert.

Um die optimale Lastverschiebung für den kommenden Tag zu berechnen, werden Prognosen für den Energieverbrauch und die Energieerzeugung für jeden teilnehmenden Haushalt verwendet. Diese Prognosen werden unabhängig von der Optimierung erstellt und die Rückkopplung zwischen den Prognosen und dem Optimierungsergebnis wird als zukünftige Option diskutiert. Es wurden Voruntersuchungen durchgeführt, um typische Haushaltsgeräte mit einem hohen Potenzial für manuelle Lastverschiebung auszuwählen. Folgende Geräte/Handlungen wurden für eine Lastverschiebung ausgewählt:

- Waschmaschine
- Geschirrspüler
- Wärmepumpe
- Ladestation (Elektroauto)
- Stromeinsparung

Jedes Gerät hat ein definiertes Lastprofil, das so modifiziert wird, dass Unsicherheiten, wie z.B. der ungenaue Einschaltzeitpunkt, kompensiert werden. Die Unsicherheiten, die sich aus dem menschlichen Verhalten ergeben, werden durch Modellierung der Akzeptanzwahrscheinlichkeit der Empfehlungen behandelt.

Der dynamische Verteilschlüssel ist eine sehr beliebte Methode zur Aufteilung des aggregierten Stromüberschusses innerhalb einer Energiegemeinschaft. Das bedeutet, dass jeder Teilnehmer / jede Teilnehmerin einen bestimmten Prozentsatz der in der Gemeinschaft verfügbaren Gesamterzeugungsleistung in Abhängigkeit von seinem/ihren Verbrauch erhält. Berücksichtigt man keine Batteriespeicher so führt dies zur nichtlinearen Gleichung (1) und kann daher nicht in einem linearen Optimierungsproblem dargestellt werden.

$$P_{C2x} = \frac{P_{load,x} - P_{PV,x}}{\sum_{i=1}^N (P_{load,i} - P_{PV,i})} \cdot \sum_{i=1}^N P_{i2C} \quad (1)$$

Für den Fall, dass ein Prosumer i Überschuss produziert, also $P_{PV,i} > P_{load,i}$ ist, gilt:

$$P_{i2C} = P_{PV,i} - P_{load,i} \quad (2)$$

und

$$P_{C2i} = 0 \quad (3)$$

Umgekehrt gilt, wenn $P_{PV,i} < P_{load,i}$:

$$P_{i2c} = 0 \quad (4)$$

und

$$P_{C2i} + P_{grid,i} = P_{load,i} - P_{PV,i} \quad (5)$$

Betrachtet man Gleichung 1 näher, so wird schnell klar, dass im Term

$$\frac{P_{load,x} - P_{PV,x}}{\sum_{i=1}^N (P_{load,i} - P_{PV,i})}$$

die elektrische Last eines Haushaltes X mit der Optimierungsvariable $P_{load,x}$ durch die Division mit der Summe der Last aller Haushalte $\sum_{i=1}^N (P_{load,i})$ ins Verhältnis mit sich selbst gesetzt wird, was zu einer nichtlinearen Abhängigkeit führt.

Beispielsweise ist die dem Haushalt Y zugewiesene Leistung (P_{C2i}) unter Berücksichtigung von (5) direkt von der Summe des Verbrauchs aller Haushalte ($\sum P_{C2i}$) und damit auch von sich selbst abhängig. Dies könnte vermieden werden, indem man das Problem ohne diese Nebenbedingung berechnet und diese Nichtlinearität bei der Nachbearbeitung berücksichtigt.

2.6 AP7: Funktionsvalidierung / Business Case: Digitale Energiegemeinschaften

Mit der Elektrizität-Richtlinie 2019/944 sowie Erneuerbare-Energie-Richtlinie 2018/2001 wurden die Bürger:innen von der EU-Kommission in den Mittelpunkt einer demokratischen Energiewende gestellt. Vor diesem Hintergrund sind Bürgerinnen und Bürger als zentrales Element einer demokratischen und sozialen Energiewende anzusehen sowie ihnen die Verantwortung zuzugestehen, sich aktiv am Energiemarkt zu beteiligen. Dabei hat die Implementierung des Funktionsmodells der serve-U App das Ziel, hierzu einen Beitrag zu leisten.

Das Hauptziel des vorliegenden Funktionsmodells ist es, dass Nutzer:innen mithilfe der serve-U App neue Gewohnheiten im Umgang mit Strom erlernen können. Damit dieses Ziel erreicht werden kann, muss das innovative Tool bedürfnisangepasst gestaltet werden. Dazu wurden geeignete Testnutzer:innen in der Entwicklung des Funktionsmodells einbezogen. Es wurde ein Kriterienkatalog zur Funktionsvalidierung entworfen, welcher Kriterien zu Akquirierung und Engagement von Nutzer:innen, Voraussetzungen und User Experience umfasst. Darüber hinaus wurden zur Erfolgsmessung der Implementierung der App in der Testumgebung Hypothesen aufgestellt und getestet.

2.6.1 Ergebnisse der Business Case Analyse

Im vorliegenden Deliverable werden mögliche Geschäftsmodelle analysiert, die zur Entwicklung der digitalen Energie-Service Plattform Serve-U und den damit verbundenen Energiegemeinschaften unterstützend wirken können. Im Projektvorhaben werden drei unterschiedliche gemeinschaftlichen Bewirtschaftungs- und Optimierungsformen auf wirtschaftliche Effizienzgewinne untersucht: (i) Analoge Energiegemeinschaften, (ii) nutzerinduzierte Verhaltensadaption und (iii) automatisierte Systemoptimierung auf Basis von eigens dafür entwickelten Optimierungsalgorithmen. Bei der Darlegung der wirtschaftlichen Handlungsräume für Anwender:innen, Energiegemeinschaften und Energieversorger

werden die unterschiedlichen Anwendungsfälle mittels einer Handlungsempfehlungsmatrix für den jeweiligen Business Case dargestellt.

2.6.1.1 Analoge Energiegemeinschaften

Analoge Energiegemeinschaften beschreiben einen Zusammenschluss von mindestens zwei oder mehreren Personen/Haushalten, die wie im Erneuerbaren-Ausbau-Gesetzespaket vorgesehen eine Energiegemeinschaft bilden, um EE (erneuerbare Energie) selbst zu produzieren und nach Möglichkeit selbst zu verbrauchen. Das Prinzip einer analogen Energiegemeinschaft ist die Aufteilung der vorhandenen Erzeugung gemäß eines definierten Aufteilungsschlüssels in 15-minütigen Zeitschritten. Dieser Aufteilungsschlüssel kann entweder dynamisch oder statisch sein. Dabei bekommt beim statischen Aufteilungsschlüssel jeder teilnehmende Haushalt einen fixierten Anteil an der momentanen Erzeugung zugeschrieben. Beim dynamischen Aufteilungsschlüssel wird die erzeugte Energie je viertel Stunde entsprechend dem Verbrauch der Haushalte aufgeteilt. Bei einer Energiegemeinschaft in seiner rudimentärsten Form kommt es zu keinerlei Energieflussoptimierung und beschreibt somit den Ausgangspunkt für das Forschungsprojekt Serve-U. Geht man beispielsweise davon aus, dass ein Großteil der Teilnehmer:innen berufstätig ist, hat das zur Folge, dass ein Ungleichgewicht entsteht zwischen Erzeugung und Verbrauch, unabhängig davon ob eine dynamische oder statische Aufteilung erfolgt. Während der Verbrauch unter Tags abnimmt und überschüssige Energie ins Netz eingespeist wird, muss die Energie bei geringerer oder keiner Sonneneinstrahlung teuer aus dem Netz bezogen werden.

Die Möglichkeit einer, so zu sagen, intelligenten Aufteilung ist in einer analogen Energiegemeinschaft nur schwer oder gar nicht möglich. Ein Beispiel hierzu wäre, wenn eine der Parteien auf Urlaub ist und keine Energie benötigt wird. Diese nicht genutzte Energie kann, aufgrund der Großteils berufstätigen Teilnehmer:innen, nicht an eine andere Partei in der Analogen Energiegemeinschaft weitergegeben werden, wodurch diese Energie dem Allgemeinen Energienetz zugeführt wird.

Um dies anschaulicher darzustellen, wird nun ein genauerer Blick auf einen realitätsnahen Business Case im Zuge des Projektes Serve-U eingegangen. Wie bereits im oberen Teil beschrieben, ist die Weitergabe von überschüssiger Energie bei diesem Modell nur begrenzt möglich. Bei diesem Geschäftsmodell verfügen die Nutzer:innen nicht über aktuelle Verbrauchs- und Erzeugungsdaten, da diese immer erst am Folgetag zur Verfügung stehen. Nicht verbrauchte Energie wird direkt in das Netz eingespeist. Der positive Effekt an diesem Schema jedoch ist, dass dies niedrigere Kosten in der Aufrechterhaltung und dem Installationsaufwand bedeutet.

Um anknüpfend auf die beiden oben genannten Punkte, Aufrechterhaltung und Installationsaufwand, näher einzugehen, ist es nötig zu erwähnen, dass hier keine Hardware (z.B. Zähler, die aktuelle Messwerte liefern) und keine Anbindung an das Internet von Nöten ist. Eine Analoge Energiegemeinschaft kann demnach offline existieren und somit Kosten einsparen. Dadurch ist dieses Geschäftsmodell einer Energiegemeinschaft weniger Fehleranfällig. Da die Gemeinschaft selbst für die Aufteilung und Abrechnung verantwortlich ist, müssen die Nutzer:innen Zeit und Geld für den Betrieb der gemeinschaftlichen Anlage selbst übernehmen.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Tabelle 3: Bewertung des Geschäftsmodells "Analoge Energiegemeinschaften"

Positiv	Negative
Geringe Kosten	Geringere Ersparnis
Weniger anfällig für Fehler	Suboptimale Nutzung der erzeugten Energie
Funktioniert offline	Keine Information über eigenen und gemeinschaftlichen Verbrauch
Keine Verhaltensänderung, kein zusätzlicher Aufwand	

2.6.1.2 Nutzerinduzierte Verhaltensadaption




Abbildung 19: Optimierungsprozess mit Visualisierung

Das Geschäftsmodell der nutzerinduzierten Verhaltensadaption bekommen Anwender:innen von Serve-U, basierend auf echtzeitnaher Visualisierung von Verbrauch und Dargebot. Energiegemeinschaften haben bei dieser Variante bereits Zugriff auf integrierte Last- und Erzeugungsprognosen, wobei die Verbrauchsmustervisualisierung von der Plattform via App jederzeit abgerufen werden kann. Die Einzigartigkeit dieser Systemvariante besteht in der Verwendung von nicht- invasiver Sensorik. Für die Funktion des Dienstes benötigt Serve-U lediglich die Daten der Smart-Meter, welche vom Netzbetreiber zur Verfügung gestellt werden und der Wechselrichter sämtlicher Teilnehmer einer Energiegemeinschaft. Vorranging dabei ist es, die erzeugte elektrische Energie innerhalb der Energiegemeinschaft zu verbrauchen und erst danach ins Netz einzuspeisen. Ein weiterer Hauptbestandteil des Serve-U Konzepts sind meteorologische Daten, die in Kombination mit aktuellen und historischen Erzeugungsdaten akkurate Erzeugungsprognosen für die zu erwartende Erzeugungsleistung liefern. Damit schafft Serve-U die Grundlage für

Anwender:innen Lastverschiebungen selbst zu planen und umzusetzen. Durch nutzerinduzierte Verhaltensmaßnahmen innerhalb der Serve-U Umgebung wird der Eigenverbrauch signifikant gesteigert und motiviert Nutzer:innen den Stromverbrauch bedarfsgerecht zu managen.

Dieses Servicekonzept zeichnet sich dadurch aus, den Eigenverbrauch der EE mittels Handlungsempfehlungen zu optimieren, mit minimalem technischem und finanziellem Aufwand. Ein Zugreifen bzw. Steuern von Komponenten innerhalb einer Energiegemeinschaft wird bewusst vermieden, da sich die Kommunikation mit automatisierbaren, flexiblen Lasten, deren Schnittstellen nicht genormt sind, als äußerst kosten- und arbeitsintensiv gestaltet.

Tabelle 4: Bewertung des Geschäftsmodells „Nutzerinduzierte Verhaltensadaption“

Positiv	Negativ
Bessere Nutzung der erzeugten Energie	Kosten der Plattform
Information über die zu erwartende Energiemenge	Plattform braucht Informationen (Smart-meter und Wechselrichter)
Nutzer können Lastverschiebung besser planen	Funktioniert nur online
KI erkennt Verhaltensmuster	Entfremdung / Permanente Nutzung?
Hohe Skalierbarkeit	
Verrechnungsschlüssel	

2.6.1.3 Automatisierte Systemoptimierung

Die automatisierte Systemoptimierung auf Basis von Modellierungsalgorithmen bietet eine umfassende informationstechnische Vernetzung aller Elemente des Energiesystems. Dieses Geschäftsmodell bietet




Abbildung 20: Optimierungsprozess mit Handlungsempfehlung

den Prosumern* die größten Effizienzgewinne, ermöglicht durch den Einsatz von selbstoptimierenden Modellierungsalgorithmen. Diese Optimierungsalgorithmen stellen ein Kernelement der Serve-U Plattform dar und umfassen eine hochauflösende meteorologische Erzeugungsabschätzung, börsenbasierte Preisdaten sowie selbstlernende Verbrauchsprognosen. Bei diesem Geschäftsmodell liegt der Fokus am monetären Nutzen für die Energiegemeinschaft und nicht für die/den individuelle/n Teilnehmer:in. Deshalb ist das Optimierungsziel das kooperative Verhalten der einzelnen Teilnehmer:innen zu erwirken, um damit die Grundlage für eine signifikante Reduktion der Energie-Kosten für die Gemeinschaft sowie auch jede/n einzelne/n Teilnehmer:in zu schaffen.

Für die Evaluierung von Flexibilisierungspotentialen verwendet das System Echtzeitdaten, sowie historische Daten als Basis für das Training von Machine-Learning Algorithmen. Dies ermöglicht es, einen optimalen Fahrplan für die nächsten 24 bis 72 Stunden bereit zu stellen, für jeden einzelnen Teilnehmer:innen in der Energy Community.

Danach werden die Energieflüsse auf der Plattform für die Nutzer:innen visualisiert und Optimierungspotentiale werden automatisiert in Handlungsempfehlungen übersetzt. Zusätzlich zu den nutzerinduzierten Lastverschiebungen, werden einzelne Lasten wie z.B. Wärmepumpen automatisiert, sowie der Einsatz von Speichertechnologien berücksichtigt. Serve-U schafft die Rahmenbedingungen den Autarkiegrad von Energiegemeinschaften zu steigern und gibt seinen Kunden die Freiheit selbst zu entscheiden, ob die produzierte Energie verbraucht, gespeichert oder verkauft werden soll.




Abbildung 21: Datenströme Serve-U

Aufgrund der hohen Skalierbarkeit bietet das Serve-U Konzept die Voraussetzung für ein profitables Wachstum, ohne die Kosten für Personalbeschaffung oder IT-Ressourcen deutlich erhöhen zu müssen. Die Open-Source Charakteristik der Plattform steigert zudem die Attraktivität für eine Reihe von Drittanbietern, die mit Programmierschnittstellen und Hardware den Automatisierungsgrad und somit die Effizienz weiter steigern können.




Abbildung 22: Faktoren die die Wirtschaftlichkeit beeinflussen

Tabelle 5: Bewertung des Geschäftsmodells „Automatisierte Systemoptimierung“

Positiv	Negativ
Optimale Nutzung der erzeugten Energie	Umfangreiche Datenschutzrechtliche Vorgaben
System ist selbstoptimierend	Lastverschiebungen müssen (sollten) automatisiert vorgenommen werden
Verwendung historischer Daten	Mehr Systemwartung benötigt
KI erkennt Verhaltensmuster	Kosten, Implementierbarkeit

2.7 AP8: Netzstabilität / Regulierung / sozio-technologische Begleitforschung

2.7.1 Rechtsanalyse

Im Rahmen der Rechtsanalyse in AP 8 (siehe dazu “Rechtsanalyse” M8.2 im Anhang) wurden die Regelungen des BEG und des EEG analysiert. Unterschiede und Gemeinsamkeiten wurden herausgearbeitet und die Schritte zur Gründung und zum Betrieb einer Energiegemeinschaft dargestellt. Die Datenbeschaffung wurde in die rechtliche Analyse mit einbezogen, da eine Energiegemeinschaft nur

mit dem Fluss von Erzeugungs- und Verbrauchsdaten funktionieren kann. Im Rahmen der Forschung wurden Stakeholder einbezogen. Durch die Analyse der rechtlichen Rahmenbedingungen und der Stakeholder konnten Barrieren identifiziert und Empfehlungen formuliert werden.

Der Rechtsrahmen für BEG und EEG kann wie folgt zusammengefasst werden: Der **Hauptzweck und die Gründung von Energiegemeinschaften erfolgen grundsätzlich gleich**, wobei verschiedene Rechtsformen genutzt werden können, bevorzugt werden jedoch Vereine und Genossenschaften. Der Rechtsrahmen im EIWOG 2010 und EAG bietet **Spielraum für unterschiedliche Konstellationen**, darunter möglicher und erlaubter Mitgliederkreis, die Integration der Erzeugungsanlagen, die Reichweite der Gemeinschaft und die Aufteilung des Stroms, **um den individuellen Bedürfnissen gerecht zu werden**. Die gesetzlichen Bestimmungen bilden die Grundlage für **vielfältige Ausprägungen von Energiegemeinschaftsprojekten**. Diese Vielfalt bietet zahlreiche Erfahrungsmöglichkeiten, die für zukünftige Energiegemeinschaften von Nutzen sein können, welche sich auch in den Stakeholder-Interviews (OurPower, ATB und Sonnenplatz die Gemeinschaften begleitet haben) von drei Energiegemeinschaften widerspiegelte.

Zum Erhalt von Daten kann folgendes kurz zusammengefasst dargestellt werden: Die gesetzlichen Vorgaben und eine Plattform erleichtern den Datenaustausch in der Energiewirtschaft. Der **aktuelle Rechtsrahmen ermöglicht eine ¼-Messung der Verbrauchsdaten und eine tägliche Abfrage**. Dies stellt die Netzbetreiber vor Herausforderungen hinsichtlich der Datenweiterleitung. Die **Regelungen sollten angepasst** werden, um den Bedürfnissen der heutigen Zeit gerecht zu werden. Daher wäre es wohl ratsam, die ambitionierten Ziele zur Dekarbonisierung des Energiebereichs und die Einbindung der Bevölkerung in die dezentrale Energieerzeugung durch einen **schnelleren und kontinuierlichen Datenfluss** zu unterstützen.

Im Zuge der Zusammenarbeit zwischen den Projektpartnern ATB Becker der EL-JKU an einem Newsletter zum Thema Energiegemeinschaften wurden die Rechercheergebnisse und Untersuchungen zu notwendigen Verträgen aus den Beziehungen zwischen den Partnern in einer EEG in einem Ablaufdiagramm und einem Diagramm zu den Beziehungen zwischen Partnern dargestellt, damit Anwendern die Abwicklung erleichtert wird. Im Newsletter wurden die rechtlichen Fragestellungen und die Abwicklungsrichtlinien in einer verständlichen Art festgehalten und an Beispielen erörtert. In einem parallel laufenden EEG-Projekt wurden die Recherchen zur Partnerverbindungen getestet und optimiert. Zudem wurden bestehende Schwachstellen aufgezeigt, die es Anwendern ermöglicht darauf zu reagieren und Lösungen zum speziellen EEG-Projekt zu finden. Zudem wurden in dem Newsletter die Erfahrungen aus der Mehrparteienhausanalyse eingearbeitet und Lösung mit einem Contracting-Modell dargestellt, das den Vorteil bietet, dass auch Mieter aus sozial ärmeren Schichten am Nutzen von erneuerbaren Energien teilhaben können. Die Ergebnisse wurden auch in einem wissenschaftlichen Artikel in der juristischen Fachzeitschrift ZTR veröffentlicht.[13]

2.7.2 Sozio-technologische Begleitforschung

Im Arbeitspaket 8 wurden Konzepte für die Anreize bzw. Motivatoren entwickelt, unter welchen die Testpersonen die serve-U App im Projekt nutzten.

Die Einbindung der Nutzer:innen in die Projekt- und Validierungsphase wurde in mehreren Schritten durchgeführt (siehe Abbildung): Informationen zum Projekt (Akquise), Erstkontakt (Teilnahme), formale Einbindung, Testphase

App und Projektende. Zur Teilnahme an der Validierungsphase wurden mehrere Voraussetzungen festgelegt (z.B. Smart Meter, Startbefragung, Zugang Laptop, etc.)




Abbildung 23: Darstellung des Schrittweisen Ablaufs der Nutzer:innen-Einbindung

Ziel der Funktionsvalidierung war die Wirksamkeit zur Aktivierung zu überprüfen, Anreiz- und Motivationskonzepte auszuprobieren, Anwendungen zu überprüfen, Feedback der Nutzer:innen einzuholen, sowie die Einstellung im Vergleich zum Start zu überprüfen.

Im Laufe der Funktionsvalidierung hat ein iterativer Prozess gezeigt, dass die Anpassung der App aufgrund des Feedbacks der Testpersonen zu einer höheren Attraktivität und leichterem Nutzung führen konnte. Die Testpersonen wurden in den Entwicklungsprozess niederschwellig integriert und als langfristige Nutzer:innen angesprochen. Als zentrale Untersuchungen standen die Aktivierung der Nutzer:innen an der Funktionsvalidierung und am Entwicklungsprozess der App, sowie die Anpassung der App an die Bedürfnisse der Nutzer:innen im Vordergrund.

Mithilfe von Co-Creation Tools, wie Befragungen und Workshops sowohl vor als auch nach der Testphase, wurden die Teilnehmer:innen eingebunden, sie konnten ihre Meinungen zusätzlich innerhalb der App während der Funktionsvalidierung kommunizieren. Die Funktionsvalidierung fand in einem zweistufigen Prozess statt, um somit Verbesserungen von der ersten Validierungsphase auf die zweite herstellen und erheben zu können. Es konnten insgesamt knapp 60 aktive Testpersonen erreicht werden, was jedoch als nicht repräsentativ gilt. Als Teilnehmende beteiligten sich besonders männliche Personen aus dem ländlichen Raum, die sich bereits vor der App-Nutzung mit energiespezifischen Themen auseinandergesetzt haben. Als ausschlaggebende Motivation an der Teilnahme nannte der Großteil der Testpersonen einen Beitrag zur Energiewende zu leisten. Der häufigste angegebene Grund zur Lastverschiebung im eigenen Haushalt waren die Nutzung erneuerbarer Energien und das Energiesparen.

Die Nutzer:innen wurden für die Testnutzung in Haushaltsgruppen und Kontrollgruppen unterteilt, wobei die Kontrollgruppe allgemeine Push-Benachrichtigungen über die App erhielt, die Haushaltsgruppen jedoch bekamen gezieltere Handlungsempfehlungen. Sie sollten in der App diese Aktionen entweder „akzeptieren“ oder „ablehnen“. Die Analyse der Benachrichtigungen bzw. Aktionen in der App zeigte, dass die Mehrheit dieser von den Nutzer:innen entweder ignoriert wurden oder es keine Rückmeldungen gab. Von den beantworteten Aktionen, wurde von beiden Gruppen auf das Empfehlungsthema „Klimaschonend“ häufiger reagiert als im Vergleich zu „Regionalem Strom“ und „Energiesparen“. Eine zeitliche Verkürzung der zweiten Durchführungsphase konnte eine Aktivierung der Nutzer:innen erzielen. Einerseits zeigte sich dies in der Zahl der Teilnehmenden der Workshops und der Befragungen, und andererseits an den Reaktionen auf die Handlungsempfehlungen bzw. Aktionen in der App.

3 Ergebnisse und Schlussfolgerungen

In den folgenden Kapiteln werden die wichtigsten Ergebnisse aus dem Projekt pro Arbeitspaket dargestellt.

3.1 AP2: Sektorkopplung und Flexibilitätsanalyse in Energiegemeinschaften

Ein White Paper, das den Umfang und die Analyse des Flexibilitätspotenzials von Haushaltsgeräten umreißt, wurde vorgelegt und ausgewertet. Die Ergebnisse und Schlussfolgerungen des Whitepapers werden im Folgenden zusammengefasst.

Das Flexibilitätspotenzial verschiedener Haushaltsgeräte und deren Lastverschiebung in Schwachlastzeiten hängt von mehreren Einflussfaktoren ab, wie der Bereitschaft der Nutzer, ihre Lasten zeitlich zu verschieben, dem Energieverbrauch des zu verschiebenden Haushaltsgeräts (Effizienzklasse, Leistungsklasse, Programm) und der Steuerbarkeit dieser Geräte. Die Bereitschaft der Nutzer wird von einer Reihe von Faktoren beeinflusst und hängt wiederum von normativen Aspekten (z. B. Umweltbewusstsein) und soziodemografischen Faktoren (z. B. Alter und Arbeitsstruktur der Haushaltsmitglieder und Haushaltgröße) ab.

Identifizierte Haushaltsverbraucher wie Backöfen, Elektroherde, Wasserkocher, Beleuchtung, TV, Audio (Hi-Fi), Spielkonsolen, PCs, Haartrockner für Koch- und Freizeitanwendungen können nicht gesteuert werden, da sie bei Bedarf sofort genutzt werden. Ihr Flexibilitätspotenzial ist daher aus Nutzersicht als sehr gering einzuschätzen. Wäschetrockner, Waschmaschinen und Geschirrspüler hingegen haben aufgrund ihrer kurzen Nutzungsdauer, der langen Schaltzeit, des relativ hohen Energieverbrauchs, einer hohen Verbreitung in Österreich und einer hohen Bereitschaft der NutzerInnen zur Lastverschiebung ein hohes Flexibilitätspotenzial. Darüber hinaus bieten Warmwasserkessel Möglichkeiten zur Lastverschiebung, solange der Nutzerkomfort nicht eingeschränkt wird. Dies gilt in geringerem Ausmaß auch für Wärmepumpen sowie Kühl- und Gefriergeräte. Um diesen Komfort zu gewährleisten, sind thermische Speichermassen mit guter Speicherkapazität und eine gute Gebäudedämmung für die Lastverschiebung von Wärmepumpen besonders wichtig.

Das ökonomische Potenzial der Lastverschiebung wird als begrenzt eingeschätzt und ist durch den weiteren Ausbau der erneuerbaren Energien und den Prozess der Lastverschiebung selbst eingeschränkt. Aus wirtschaftlicher Sicht sind nur Geräte mit hohem Energieverbrauch für eine Lastverschiebung geeignet. Die Wärmepumpe hat hier den größten Beitrag geleistet. Die häufig diskutierte Lastverschiebung

von konventionellen Haushaltsgeräten (z.B. Waschmaschinen, Trockner, etc.) wird dagegen unter den angenommenen Rahmenbedingungen als nicht wirtschaftlich angesehen.

Grundsätzlich wirkt sich die Bereitstellung flexibler Kapazitäten auf der Nachfrageseite positiv auf die Umwelt aus, da sie die Integration erneuerbarer, fluktuierender Energiequellen bei gleichzeitiger Aufrechterhaltung der Versorgungssicherheit erleichtert, die aus erneuerbaren Energiequellen gewonnene Energie besser nutzt, Spitzenlasten, die häufig durch Gaskraftwerke oder Pumpspeicherkraftwerke abgedeckt werden, reduziert und den Energieverbrauch insgesamt senkt. Letztlich führt dies auch zu einer Verringerung der CO₂-Emissionen aus Energieerzeugung und -verbrauch.

3.2 AP3: Konzeption Erzeugungsprognoseplattform

Die Qualität der meteorologischen Prognosen, die mit einer Auflösung von einer Stunde zur Verfügung stehen, werden für den Vorhersagezeitraum „Day Ahead“, das heißt für die Vorhersagestunden 25 bis 48 verifiziert. Laut Stand der Technik werden folgende Fehlermaße angewendet:

BIAS

Der mittlere Fehler (BIAS) ist die durchschnittliche Abweichung der Prognose zu den beobachteten Werten (Messwerte)

$$BIAS = \frac{1}{\text{Anzahl der Prognosen}} \sum (Prognose - \text{Messwert})$$

MAE

Der mittlere absolute Fehler (MAE) ist der durchschnittliche Betrag der Abweichung der Prognose zu den beobachteten Werten.

$$MAE = \frac{1}{\text{Anzahl der Prognosen}} \sum |Prognose - \text{Messwert}|$$

RMSE

Der Root Mean Square Error (RMSE) entspricht der Quadratwurzel des mittleren quadratischen Fehlers.

$$RMSE = \sqrt{\frac{1}{\text{Anzahl der Prognosen}} \sum (Prognose - \text{Messwert})^2}$$

rMAE

Der relative absolute Fehler (rMAE) ist bei Strahlungs- und PV Prognosen normiert mit der durchschnittlichen Strahlung/PV-Leistung zu den Tagesstunden (Strahlung > 1 Watt) bzw. bei Windkraftprognosen erfolgt die Normierung zur installierten Leistung (kWp).

$$rMAE = \frac{MAE}{\text{durchschnittliche Strahlung, PV oder Wind kWp}}$$

rRMSE

Der relative Root Mean Square Error (rRMSE) ist bei Strahlungs- und PV Prognosen normiert mit der durchschnittlichen Strahlung/PV-Leistung zu den Tagesstunden (Strahlung > 1 Watt) bzw. bei Windkraftprognosen erfolgt die Normierung zur installierten Leistung (kWp).

$$rRMSE = \frac{RMSE}{\text{durchschnittliche Strahlung, PV oder Wind kWp}}$$

3.2.1 Ergebnisse, Prognosegenauigkeit: Meteorologische PV- und Windkraftprognosen

3.2.1.1 Ergebnisse Windkraftmodelle

Für den Windpark Spörbichl wurden die Day-Ahead-Prognosen (MOS) im Zeitraum 01.11.2022 – 01.11.2023 verifiziert. Der mittlere Fehler (BIAS) lag bei 23,22 kW, der mittlere absolute Fehler (MAE) bei 90,8 kW, normiert mit der installierten Leistung (1320 kWp) ergibt das einen relativen mittleren absoluten Fehler (rMAE) von 7,2 %. Die Benchmark von sehr guten Windkraftprognosen liegt in einem Bereich von < 10 % und wurde damit erfüllt.

DMO-Modelle wurden für die Windkraftanlagen nicht berechnet, da ohne Ganglinie und genaue Kenntnis des Windparks (Reibungslänge, Ganglinie, Nabenhöhe) keine Modellierung möglich ist.




Abbildung 11: PV-Prognose Spörbichl MOS: blau, Messwert: rot

Methode	BIAS (kW)	MAE (kW)	rMAE (%)
MOS	23,2	90,8	7,2
DMO	--	--	--

Tabelle 2: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE der Windkraftmodelle für Spörbichl. (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.12.2023)

3.2.1.2 Ergebnisse PV-Modelle

Die Validierung erfolgte für mehrere PV-Großanlagen am Standort Strem (Ourpower) im Burgenland und kleiner PV-Anlagen in Großschönau (Sonnenplatz) im Waldviertel. Untersucht wurden nur die Tagesstunden, definiert mit einer gewissen Mindestleistung. Dieser Grenzwert lag je nach Größe der Anlagen zwischen >= 3 Watt und >= 100 Watt.

Der Trainingszeitraum der MOS-Modelle und die Datenbasis für die Funktion der DMO-BS-Methode für Strem lag zwischen 01.10.2020 und 30.06.2022, der Validierungszeitraum zwischen 01.11.2022-01.11.2023. Der mittlere Fehler (BIAS) der MOS-Modelle für zwei PV-Großanlagen (1566 kWp und 183 kWp) war erwartungsgemäß niedrig. Der relative mittlere absolute Fehler (rMAE) lag bei beiden Anlagen

und allen Prognosemethoden zwischen 21,9 % und 23,8 %, der relative Root Mean Square Error (rRMSE) zwischen 34,9 % und 36,3 %. Die Benchmark für sehr gute PV-Prognosen liegt bei einem rMAE von unter 30 % und einem rRMSE um 40 %. Dies wurde bei allen Modellen erfüllt, wobei die Ergebnisse der DMO-BS-Methode geringfügig besser abschnitten als die MOS-Modelle (siehe Tabelle 6 und Tabelle 7).

Tabelle 6: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE und rRMSE der PV-Modelle für den Standort Strem (1566 kWp). (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.11.2023, untersucht wurden nur Stunden mit Leistung ≥ 100 W)

Methode	BIAS (kW)	MAE (kW)	rMAE (%)	rRMSE (%)
MOS	-10,9	108,2	23,2	35,0
DMO-BS	-10,8	102,3	21,9	34,9

Tabelle 7: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE und rRMSE der PV-Modelle für den Standort Strem (183 kWp). (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.11.2023, untersucht wurden nur Stunden mit Leistung ≥ 3 W)

Methode	BIAS (kW)	MAE (kW)	rMAE (%)	rRMSE (%)
MOS	-1,0	12,7	23,8	36,3
DMO-BS	-0,7	11,8	22,1	35,1

Der Trainingszeitraum der MOS-Modelle und die Datenbasis für die Funktion der DMO-BS-Methode für Großschönau lag zwischen 01.06.2021 und 31.12.2022, der Validierungszeitraum zwischen 01.11.2022-01.11.2023. Im Validierungszeitraum gab es zwei größere Episoden, an denen Schnee auf den PV-Anlagen eine Stromproduktion verhinderte und zwar im Zeitraum 13.-22.12.2022 und 22.01.-01.02.2023. Diese Zeiträume wurden für die Validierung nicht verwendet. Der mittlere Fehler (BIAS) der MOS-Modelle für die vier PV-Anlagen (22,8 kWp, 5,3 kWp 8,5 kWp und 20,6 kWp) war erwartungsgemäß nahe Null, dass der BIAS der DMO-BS-Methode ebenfalls nahe Null lag, war überraschend und deutet auf keine markanten systematischen Fehler hin. Der relative mittlere absolute Fehler (rMAE) lag bei allen Modellen in Sonnenplatz Großschönau zwischen 26,8 % und 33,1 %, der relative Root Mean Square Error (rRMSE) zwischen 39,3 % und 48,8 %. Die Benchmark für sehr gute PV-Prognosen liegt bei einem rMAE von unter 30 % und einem rRMSE um 40 %. Dies wurde bei fast allen Modellen erfüllt, wobei die MOS-Prognosen um 1-3 Prozentpunkte, bei der 5,3 kWp Anlage um etwas mehr als 5-6 Prozentpunkte besser abschnitten als die DMO-BS-Methode. Generell war der Prognosefehler in Großschönau größer als in Strem. Dies liegt vor allem daran, dass im Südburgenland generell stabilere Wetterlagen herrschen und es weniger Tage mit Schnee auf den PV-Anlagen gibt, die die Ergebnisse verfälschen (siehe Abbildungen 5 bis 8).

Tabelle 8: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE und rRMSE der PV-Modelle für den Standort Sonnenplatz Großschönau (22,8 kWp). (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.11.2023, untersucht wurden nur Stunden mit Leistung ≥ 60 W)

Methode	BIAS (kW)	MAE (kW)	rMAE (%)	rRMSE (%)
MOS	-0,01	1,77	27,1	40,9
DMO-BS	0,0	1,90	29,1	42,6

Tabelle 9: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE und rRMSE der PV-Modelle für den Standort Sonnenplatz Großschönau (5,3 kWp). (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.11.2023, untersucht wurden nur Stunden mit Leistung >= 12 W)

Methode	BIAS (kW)	MAE (kW)	rMAE (%)	rRMSE (%)
MOS	0,08	0,40	26,9	40,5
DMO-BS	0,06	0,42	28,4	41,8

Tabelle 10: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE und rRMSE der PV-Modelle für den Standort Sonnenplatz Großschönau (8,5 kWp). (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.11.2023, untersucht wurden nur Stunden mit Leistung >= 4 W)

Methode	BIAS (kW)	MAE (kW)	rMAE (%)	rRMSE (%)
MOS	0,15	0,59	26,8	42,5
DMO-BS	-0,04	0,72	33,1	48,8

Tabelle 11: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE und rRMSE der PV-Modelle für den Standort Sonnenplatz Großschönau (20,6 kWp). (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022-01.11.2023, untersucht wurden nur Stunden mit Leistung >= 15 W)

Methode	BIAS (kW)	MAE (kW)	rMAE (%)	rRMSE (%)
MOS	0,22	1,53	26,8	39,9
DMO-BS	0,19	1,83	30,5	42,8

3.2.2 Ergebnisse, Prognosegenauigkeit: Datenbasierte PV-Produktionsprognosen

Wir haben die Leistung der Standardprognosemodelle im Hinblick auf den durchschnittlichen RMSE und über mehrere Simulations-/Testzeiträume von einem Tag bis zu einem Jahr bewertet. Für jedes Prognosemodell wird zu Beginn eines jeden Tages d des Simulationszeitraums eine Prognosezeitreihe über den gesamten Tag d erstellt. Am Ende dieses Tages wird der RMSE des Modells $\times$ auf der Grundlage der tatsächlichen PV-Produktionsmessungen während des Tages berechnet, und er ist definiert als

$$E_d^{\times} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_d^{\times}(t) - y_d(t))^2}$$

Wenn sich der Simulationszeitraum über mehrere Tage erstreckt (z. B. 1 Jahr), wird der Tagesdurchschnitt des RMSE ebenfalls über den gesamten Simulationszeitraum von N Tagen berechnet, der wie folgt definiert ist

$$\bar{E}^{\times} = \frac{1}{N} \sum_{d=1}^N E_d^{\times}$$

Diese Berechnungen wurden mit realen PV-Erzeugungsmessungen durchgeführt, die von drei Wohngebäuden in Oberösterreich im Zeitraum vom 01.01.2016 bis zum 31.12.2016 gesammelt wurden. Dies definiert auch unseren maximalen Simulationszeitraum, dessen Beginn auf den 01.01.2016 festgelegt ist. In den folgenden Unterabschnitten stellen wir die Ergebnisse der betrachteten datenbasierten Prognosemethoden für die PV-Erzeugung in den Testwohngebäuden vor.

3.2.3 Gesamtleistungsvergleich

In der folgenden Tabelle wird der tägliche durchschnittliche relative RMSE über verschiedene Simulationszeiträume für alle datenbasierten Vorhersagemethoden und für die gesamte Energiegemeinschaft dargestellt. Die Leistung wurde nach 2 Monaten Training (im Februar 2016), 7 Monaten Training (im Juli 2016) und 12 Monaten Training (im Dezember 2016) erfasst. Am Ende eines jeden Tages werden die PV-Erzeugungsprognosen für den nächsten Tag erstellt. Der RMSE wird dann berechnet, wenn die tatsächliche PV-Produktion am Ende des nächsten Tages bekannt wird. Die beste Leistung zeigte das PAR-W-Modell, das sowohl die Persistenzfaktoren als auch die Wettervorhersage für den nächsten Tag berücksichtigt. Man beachte, dass die beste Vorhersagegenauigkeit in den Sommermonaten zu beobachten ist. Dies dürfte auf die Tatsache zurückzuführen sein, dass die PV-Produktion in diesen Monaten gleichmäßiger ist. Im Winter hingegen kann es zu größeren stochastischen Schwankungen in der Produktion kommen (z. B. aufgrund von Wetteränderungen).

Tabelle 12: Relativer RMSE-Vergleich der untersuchten datenbasierten Erzeugungsprognoseverfahren

Duration	01-02/2016	01-07/2016	01-12/2016
N-days	0,782	0,634	0,910
PAR	0,873	0,665	0,930
PAR-W	0,771	0,560	0,781




Abbildung 12: Laufender durchschnittlicher RMSE der Vorhersagemodelle für den nächsten Tag über einen Zeitraum von einem Jahr für einen einzelnen Haushalt (vom 01.01.2016 bis 31.12.2016)

3.2.4 Zusammenfassung

Die meteorologischen Erzeugungsprognosen basieren auf den Ergebnissen von numerischen Wetterprognosemodellen (NWP). Die Ergebnisse dieser NWP sind rein physikalische/meteorologische Parameter, sogenannte „Direct Model Outputs“ (DMOs) wie Lufttemperatur, Solarstrahlung,

Windgeschwindigkeit, usw., die für einen Zeitraum von bis zu 384 Stunden in die Zukunft weltweit zur Verfügung stehen. Mit Umrechnungsfaktoren (Ganglinien von PV-Anlagen und Windturbinen) und der Berücksichtigung der Umgebungsfaktoren (wie z.B. Oberflächenrauigkeit, Ausrichtung der PV-Panels,..) kann man daraus Erzeugungsprognosen für Windkraft und Solarkraft entwickeln. Wenn historische Messwerte der Energieerzeugung zur Verfügung stehen, können mit statistischen Methoden MOS-Prognosen („Model Output Statistics“) entwickelt werden, die aufgrund von meteorologischen Prognosewerten die Erzeugung von Windkraft- und PV-Anlagen direkt vorhersagen können. Die Qualität der meteorologisch basierten Modelle wurde für den Vorhersagezeitraum „Day Ahead“ (Vorhersagestunde 25-48) in der Benchmarkingperiode von einem Kalenderjahr (01.12.2022-01.12.2023) ermittelt, als repräsentative Fehlermaße dienten der relative mittlere absolute Fehler (rMAE) und der relative Root Mean Square Error (rRMSE). Die Prognosen wurden für Erzeugungsstandorte der Projektpartner Ourpower und Sonnenplatz in Spörbichl (Windpark 1320 kWp), Strem (2 PV Anlagen 1566 kWp, 183 kWp) und in Großschönau (4 PV Anlagen 22,8 kWp, 5,3 kWp, 8,5 kWp, 20,6 kWp) erstellt. Für die Windkraft wurden nur MOS-Modelle gerechnet, die mit einem rMAE von 7,2 % sehr gute Ergebnisse erlangten. Bei den PV-Prognosen für die Großanlagen in Strem lagen die rMAE zwischen 21,9 % und 23,8 %, die rRMSE zwischen 34,9 % und 36,3 %. Gemäß Stand der Technik sind dies sehr gute Ergebnisse, wobei die Ergebnisse der DMO-BS-Methode geringfügig besser abschnitten als die MOS-Modelle. Bei den vier PV-Standorten in Großschönau schnitten die MOS-Modelle deutlich besser ab als die DMO-BS-Methode. Die Ergebnisse waren gut bis sehr gut und lagen beim rMAE zwischen 26,8 % und 33,1 % und beim rRMSE zwischen 39,3 % und 48,4 %. Generell war der Prognosefehler in Großschönau größer als in Strem, das liegt vor allem daran, dass im Südburgenland stabilere Wetterlagen herrschen und es weniger Tage mit Schnee auf den PV-Anlagen gibt.

Demgegenüber steht der zweite Ansatz von rein datenbasierten Erzeugungsprognosen. Es wurden drei Schlüsselmethoden untersucht und zwar a) Persistenzmodelle (N-days), b) Persistenzbasierte autoregressive Modelle (PAR) und c) Persistenzbasierte autoregressive Modelle, kombiniert mit Wetterprognosen (PAR+W). Die Evaluierung der Day-Ahead-Prognosen wurde ebenfalls in einem Kalenderjahr, außerhalb des Trainingszeitraums durchgeführt. Die Qualität der datenbasierten Methoden (rRMSE: N-days 91,0 %, PAR 93,0 %, PAR-W 78,1 %) war erwartungsgemäß deutlich niedriger als die der meteorologisch basierten Erzeugungsprognosen.

3.3 AP4: Datengetriebene Lastprognoseplattform und Systemsicherheit

3.3.1 Ergebnisse, Prognosegenauigkeit: Meteorologische Temperatur-, Strahlungs- und Lastprognosen

In einem ersten Schritt wurden für 6 Standorte (siehe Tabelle 2) Temperatur- und Strahlungsmodelle trainiert und entwickelt. Alle Modelle wurden für einen Prognosezeitraum von 96 Stunden gerechnet, in stündlicher Auflösung. Die Modelle werden alle 6 Stunden neu erzeugt. In dieser Auswertung wurde nur der 00 UTC Lauf berücksichtigt.

Tabelle 13: Prognosestandorte und die dazugehörigen Wetterstationen

Prognoseorte	Alternative Wetterstation für MOS Modelle
4040 Linz-Urfahr	Linz-Stadt
4173 St. Veith/Mühlkreis	Reichenau im Mühlkreis
4551 Ried im Traunkreis	Kremsmünster
4641 Steinhaus	Wels
4653 Eberstalzell	Kremsmünster
4710 Grieskirchen	Waizenkirchen

Die MOS-Prognosen wurden im Zeitraum 01.01.2019 -3 1.12.2021 trainiert. Die Modellqualität der Day-Ahead-Prognosen (Vorhersage für den Zeitraum Vorhersagestunde 25 – 48, mit stündlicher Auflösung) wurde im Zeitraum 01.11.2022 - 01.11.2023 evaluiert.

3.3.1.1 Ergebnisse Temperaturmodelle

Der mittlere Fehler (BIAS) der MOS-Modelle lag ziemlich genau bei 0 °C, das entspricht der Charakteristik von statistischen Modellen, der mittlere absolute Fehler (MAE) lag bei allen Standorten um 1,2 °C, und dadurch, gemäß Stand der Technik, für Day-Ahead-Prognosen in einem sehr guten Bereich (Ergebnisse siehe Tabelle 14). Der BIAS der DMO-Modelle lag zwischen -1,73 und +0,06 °C, der MAE erwartungsgemäß deutlich höher zwischen 1,34 und 2,17 °C. Hierbei ist zu erwähnen, dass die Validierung der DMO Prognosen nur mithilfe von Messwerten von Wetterstationen (siehe Tabelle 13) zu bewerkstelligen war, die teilweise einige Kilometer entfernt lagen. Das verschlechtert die Ergebnisse der DMO Validierung.

Tabelle 14: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE) der Temperaturmodelle für die 6 Standorte. (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022.-01.11.2023)

Temperatur	MOS		DMO	
Ort	BIAS	MAE	BIAS	MAE
Linz-Urfahr	0,1	1,17	-1,73	2,17
St. Veith/Mühlkreis	0,05	1,15	0,06	1,34
Ried im Traunkreis	0,03	1,15	-1,06	1,88
Steinhaus	-0,02	1,22	-0,72	1,73
Eberstalzell	0,03	1,15	-0,96	1,94
Grieskirchen	0,01	1,19	-0,41	1,62

Für den Standort Großschönau wurden weitere Modelle entwickelt und deren Qualität im Validierungszeitraum 01.11.2022 - 01.11.2023 ermittelt.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 24: Temperaturprognose Großschönau (blau-DMO, grün-MOS, rot-Messwert)

Die Qualität des MOS-Modells war etwas genauer, der MAE betrug 1,12 °C (MOS) bzw. 1,26 °C (DMO).

Tabelle 15: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE) der Temperaturmodelle für Großschönau. (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022 - 01.11.2023)

Methode	BIAS (°C)	MAE (°C)
MOS	-0,13	1,12
DMO	0,13	1,26

3.3.1.2 Ergebnisse Globalstrahlungsmodelle

Untersucht wurden nur die Tagesstunden ($GHI > 1 \text{ W/m}^2$). Der mittlere Fehler (BIAS) der MOS-Modelle war erwartungsgemäß niedrig und lag im Bereich zwischen -8,75 und +1,38 W/m^2 . Der mittlere absolute Fehler (MAE) der MOS-Modelle lag im Bereich um 60 W/m^2 , der relative MAE (rMAE), normiert um den mittleren Stundenwert der gemessenen Strahlung im Evaluierungszeitraum, bewegte sich zwischen 23 und 25 % (siehe Tabelle 16). Das entspricht gemäß Stand der Technik einem sehr guten Ergebnis. Der BIAS der DMO-Modelle lag zwischen 4,86 und 20,57 W/m^2 , der MAE um 68 W/m^2 , verhältnismäßig höher waren auch die Werte für den rMAE (26-28 %).

Tabelle 16: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE der Strahlungsmodelle für die 6 Standorte. (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022 - 01.11.2023, untersucht wurden nur Stunden mit $GHI > 1 \text{ W/m}^2$)

Strahlung	MOS			DMO		
	BIAS	MAE	rMAE	BIAS	MAE	rMAE
Linz-Urfahr	-3,8	62,3	25 %	13,94	67,0	26 %
St. Veith/Mühlkreis	-1,95	62,84	25 %	4,86	69,01	27 %
Ried im Traunkreis	-2,79	59,57	23 %	12,81	69,19	27 %
Steinhaus	1,38	58,81	24 %	20,57	69,57	28 %
Eberstallzell	-2,79	59,57	23 %	12,35	69,15	27 %
Grieskirchen	-8,75	61,39	24 %	9,91	67,0	26 %

Für den Standort Großschönau wurden weitere Modelle (siehe Abbildung 25) entwickelt und deren Qualität im Validierungszeitraum 01.11.2022 - 01.11.2023 ermittelt.




Abbildung 25: Globalstrahlungsprognose Großschönau (schwarz-DMO, grün-MOS, rot-Messwert)

Die Prognosequalität unterschied sich ähnlich wie bei den vorangegangenen Evaluierungen. Die rMAE der MOS Prognosen für den Day-Ahead-Bereich lag bei 25 %, der der DMO-Prognosen bei 29 % (siehe Tabelle 17).

Tabelle 17: Durchschnittlicher Fehler (BIAS) und durchschnittlicher absoluter Fehler (MAE), sowie rMAE der Strahlungsmodelle für Großschönau. (Day Ahead, 00-UTC Lauf, stündliche Auflösung, Zeitraum 01.11.2022 - 01.11.2023, untersucht wurden nur Stunden mit GHI > 1 W/m²)

Methode	BIAS (W/m²)	MAE (W/m²)	rMAE (%)
MOS	4,83	56,37	25
DMO	32,42	64,73	29

3.3.2 Ergebnisse, Prognosegenauigkeit: Day-ahead Datenbasierte Prognosen

Wir haben die Leistung der Standardprognosemodelle im Hinblick auf den durchschnittlichen RMSE und über mehrere Simulations-/Testzeiträume von einem Tag bis zu einem Jahr bewertet. Für jedes Prognosemodell wird zu Beginn eines jeden Tages d des Simulationszeitraums eine Prognosezeitreihe über den gesamten Tag d erstellt. Am Ende dieses Tages wird der RMSE des Modells $\times$ auf der Grundlage der tatsächlichen Stromlastmessungen während des Tages berechnet, und er ist definiert als

$$E_d^{\times} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_d^{\times}(t) - y_d(t))^2}$$

Wenn sich der Simulationszeitraum über mehrere Tage erstreckt (z. B. 1 Jahr), wird der Tagesdurchschnitt des RMSE ebenfalls über den gesamten Simulationszeitraum von N Tagen berechnet, der wie folgt definiert ist

$$\bar{E}^{\times} = \frac{1}{N} \sum_{d=1}^N E_d^{\times}$$

Diese Berechnungen wurden mit realen Stromlastmessungen durchgeführt, die von drei Wohngebäuden in Oberösterreich im Zeitraum vom 01.01.2016 bis 31.12.2016 gesammelt wurden. Dies definiert auch unseren maximalen Simulationszeitraum, dessen Beginn auf den 01.01.2016 festgelegt ist. In den folgenden Unterkapiteln stellen wir die Ergebnisse der betrachteten datenbasierten Prognosemethoden für die Stromlast in den Testwohngebäuden vor.

3.3.2.1 Beispiel-Prognosen

In diesem Unterabschnitt werden Beispielprognosen für die in den vorangegangenen Abschnitten vorgestellten Standardprognosemodelle vorgestellt, darunter Persistenzmodelle (N-days und N-same-days, mit $N = 3$), HW-Modell, SARIMA-Modell, persistenzbasiertes autoregressives Modell (PAR), persistenzbasiertes autoregressives Modell mit Wetter (PAR-W), saisonales persistenzbasiertes regressives Modell (SPR), saisonales persistenzbasiertes neuronales Netzmodell (SPNN), Verallgemeinertes additives Modell auf der Grundlage des Prophet-Algorithmus von Facebook (Prophet) und Long Short-Term Memory Model (LSTM). Die Ergebnisse werden in den folgenden Abbildungen über einen Zeitraum von einem Monat dargestellt.



Abbildung 26 Beispielprognose des Persistenzmodells "N-days" mit $N = 3$ (vom 01.07.2016 bis 31.07.2016)

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 27 Beispielprognose des Persistenzmodells "N-same-days" mit $N = 3$ (vom 01.07.2016 bis 31.07.2016)



Abbildung 28 Beispielprognose des HW-modells (vom 01.07.2016 bis 31.07.2016)

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG



Abbildung 29 Beispielprognose des SARIMA-modells (vom 01.07.2016 bis 31.07.2016)



Abbildung 30 Beispielprognose des PAR-modells (vom 01.07.2016 bis 31.07.2016)

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG



Abbildung 31 Beispielprognose des PAR-W-modells (vom 01.07.2016 bis 31.07.2016)



Abbildung 32 Beispielprognose des SPR-modells (vom 01.07.2016 bis 31.07.2016)

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG



Abbildung 33 Beispielprognose des SPNN-modells (vom 01.07.2016 bis 31.07.2016)




Abbildung 34 Beispielprognose des Facebook Prophet-modells (vom 01.07.2016 bis 31.07.2016)




Abbildung 35 Beispielprognose des LSTM-modells (vom 01.07.2016 bis 31.07.2016)

3.3.2.2 Gesamtleistungsvergleiche

In der folgenden Tabelle wird der tägliche durchschnittliche relative RMSE über verschiedene Simulationszeiträume für alle datenbasierten Vorhersagemethoden dargestellt. Die Leistung wurde nach 2 Monaten Training (im Februar 2016), 7 Monaten Training (im Juli 2016) und 12 Monaten Training (im Dezember 2016) aufgezeichnet. Wir stellen auch den Gesamttagesdurchschnitt des RMSE über das gesamte Jahr (2016) dar. Es ist offensichtlich, dass das PAR-Modell alle anderen Modelle übertrifft. Dies ist auf die Tatsache zurückzuführen, dass das PAR-Modell speziell für die Lastvorhersage entwickelt wurde und sowohl nieder- als auch hochfrequente Faktoren berücksichtigt. Andererseits sind Black-Box-Modellansätze wie SARIMA, HW, FBProphet und LSTM generische Prognoseansätze, die eine sorgfältige Konfiguration erfordern. Außerdem sollten wir erwähnen, dass SARIMA und LSTM ein rechenintensives Training mit historischen Daten über mehrere Monate erfordern. Ihre Leistung kommt der Leistung des PAR-Modells recht nahe (z. B. wenn wir ihre Leistung im Dezember 2016 vergleichen), allerdings wird dies erst nach zwölf Monaten Training erreicht.

Tabelle 18 Relativer RMSE-Vergleich der untersuchten datenbasierten Standardlastprognoseverfahren

Duration	Feb 2016	July 2016	Dec 2016	2016
N-days	0,664	0,752	0,467	0,621
N-same-days	0,843	0,868	0,546	0,731
HW	0,713	0,846	0,527	0,678
SARIMA	0,632	0,801	0,497	0,634
PAR	0,500	0,724	0,474	0,543
PAR-W	0,489	0,711	0,455	0,532

SPR	0,669	0,852	0,533	0,682
SPNN	0,789	0,803	0,487	0,681
FBProphet	0,766	0,768	0,490	0,667
LSTM	0,616	0,843	0,535	0,653




Abbildung 36 Laufender durchschnittlicher RMSE von Vorhersagemodellen für den nächsten Tag über einen Zeitraum von einem Jahr auf Gemeinschaftsdaten (vom 01.01.2016 bis 31.12.2016)

Es ist wichtig zu erwähnen, dass SPR- und SPNN-Modelle kausale Inferenzfaktoren einbeziehen, die für das Verhalten der Nutzer relevant sind (wie in den Tasks 4.2 und 4.3 geplant). Die Einbeziehung solcher Faktoren kann zwar die Leistung von Black-Box-Modellen erreichen, aber nicht die Leistung des einfacheren Modells PAR übertreffen. Der Grund dafür liegt darin, dass die Vorhersagen hier für einen Tag im Voraus erstellt werden, so dass kausale Effekte nicht genutzt werden können. Solche kausalen Effekte werden bei stündlichen Vorhersagen relevanter, wie wir in einem der nächsten Abschnitte sehen werden.

3.3.3 Ergebnisse, Prognosegenauigkeit: Stündliche Prognosen

In diesem Abschnitt stellen wir die Simulationsergebnisse unserer Prognosemethoden bei der Erstellung stündlicher Prognosen vor. Bei stündlichen Prognosen können bestimmte Phänomene im Verhalten der Nutzer ausgenutzt werden, um genauere Vorhersagen für die nächsten Stunden zu erstellen. Wenn wir beispielsweise in den Morgenstunden bereits eine Stromverbrauchsspitze beobachtet haben, dann ist es sehr wahrscheinlich, dass es in den Morgenstunden keine weitere Verbrauchsspitze geben wird. Aus diesem Grund erwarten wir, dass das Modell SPR, das die Kausalität im Verhalten der Nutzer ausnutzt, einen Vorteil gegenüber Black-Box-Modellierungstechniken hat.

Zu diesem Zweck haben wir unsere Ansätze für die Day-Ahead-Modellierung von PAR und SPR weiterentwickelt, um auch stündliche Prognosen (mit einem Vorhersagehorizont von 4 Stunden) erstellen zu können. Zum Zeitpunkt der Erstellung der Prognosen wird davon ausgegangen, dass alle früheren

Messungen bekannt sind. Die folgenden Modelle wurden aktualisiert, um stündliche Prognosen zu erstellen:

1. Persistenzbasiertes autoregressives Modell (PAR)
2. Auf saisonaler Persistenz basierendes Regressionsmodell (SPR)

Persistenzmodelle wie N-Tage und N-gleiche Tage sowie die maschinellen Lernmodelle Holt-Winters und SARIMA wurden von der Änderung ausgeschlossen, da sie für tägliche Vorhersagen konzipiert sind. Auch das LSTM-Modell wurde nicht berücksichtigt, da eine in 4-Stunden-Intervalle unterteilte Tagesfolge das Training separater Modelle für jedes Intervall erfordern würde, was rechnerisch sehr aufwändig wäre. In diesem Fall erscheint das PAR-Modell vielversprechend, da es mit konsistenten Daten in einer autoregressiven funktionalen Beziehung arbeitet. Andererseits kann das PAR-W-Modell aufgrund des Mangels an Online-Wetterdaten nicht angewendet werden. Der Persistenzteil des PAR-Modells wurde durch das N-Tage-Modell definiert, und seine endgültige Realisierung wurde PARE (erweitertes persistenzbasiertes autoregressives Modell) genannt.

Das SPR-Modell, das den Vorteil hat, kausale Effekte im Verhalten der Nutzer zu erfassen, wurde ebenfalls aktualisiert, um die Erstellung von stündlichen Prognosen zu ermöglichen. Das abgeleitete Modell wird als stündliches saisonales persistenzbasiertes regressives Modell (SPR-H) bezeichnet und enthält die in Tabelle 2 aufgeführten Merkmale, nämlich

- Elektrizitätslast aus früheren Zeitstempeln
- Rollierende Summe des 1-Stunden-Fensters
- Wochenend-Flagge
- Stündliche Last (Gesamtlast in 1h)
- Teil der mittleren Tageslast
- Differenz zwischen stündlichen Lasten
- Schwellenwerte für niedrige und hohe Last

Die oben genannten Merkmale wurden zu verschiedenen Zeitpunkten aufgenommen, um verschiedene Arten von zeitlichen Abhängigkeiten im Verhalten der Nutzer zu erfassen. Insbesondere haben wir die oben genannten Merkmale zu den folgenden Zeitpunkten betrachtet.

- T1: letzte RUN-Zeit mit verfügbarer Last
- T2: nächste RUN-Zeit von gestern
- T3: die gleiche Zeit von gestern
- T4: die gleiche Zeit der letzten N Tage (N = 14)

Diese Zeitstempel sind auch in der folgenden Abbildung zu sehen.




Abbildung 17 Zeitstempel-Spezifikationsset für das stündliche saisonale persistenzbasierte regressive Modell (SPR-H)

Die Ergebnisse der Bewertung der Genauigkeit der stündlichen Vorhersagen sind in der folgenden Tabelle und den Abbildungen dargestellt. Man beachte, dass das PARe-H-Modell, das das N-Tage-Modell für die Persistenzfaktoren verwendet, das PAR-H-Modell übertrifft, das stattdessen das N-gleiche-Tage-Modell verwendet. Außerdem ist das SPR-H-Modell erwartungsgemäß genauer als die Modelle PAR-H und PARe-H. Diese Verbesserung ist darauf zurückzuführen, dass das SPR-H-Modell mehrere kausale Effekte einbezieht, die das Verhalten der Nutzer charakterisieren. Da wir Prognosen über die nächsten 4 Stunden erstellen, gewinnen solche Effekte an Bedeutung.

Tabelle 19 Relative RMSE-Vorhersagegenauigkeit der stündlichen Prognosen

Duration	Feb 2016	July 2016	Dec 2016	2016
PAR-H	0,509	0,676	0,432	0,529
PARe-H	0,455	0,664	0,429	0,498
SPR-H	0,433	0,615	0,398	0,464

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 18 Beispielprognose des Facebook PAR-H-modells (vom 01.07.2016 bis 31.07.2016)




Abbildung 19 Beispielprognose des Facebook PARE-H-modells (vom 01.07.2016 bis 31.07.2016)

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 20 Beispielprognose des Facebook SPR-H-modells (vom 01.07.2016 bis 31.07.2016)




Abbildung 21 Laufender durchschnittlicher RMSE der stündlichen Lastprognosemethoden über einen Zeitraum von einem Jahr (vom 01.01.2016 bis 31.12.2016)




Abbildung 22 Laufender durchschnittlicher RMSE der vorgedungen und stündlichen Lastprognosemethoden über einen Zeitraum von einem Jahr (vom 01.01.2016 bis 31.12.2016)

3.3.4 Ergebnisse, Prognosegenauigkeit: Daten-basierte vorgedungen Lastprognosemethoden

In diesem Abschnitt bieten wir eine vergleichende Analyse der datenbasierten fortgeschrittenen Lastprognosemethoden, die wir in Methoden vorgestellt haben: Methoden: Fortgeschrittene Daten-basierte Lastprognosemethoden. Insbesondere werden wir eine vergleichende Adaptive Modellumschaltung, der Ensemble-Modellierung und der Auf Kausal-Inferenz basierende Lastprognosen vorstellen. Wir bieten auch einen Vergleich mit der Leistung der besten Standardlastprognosemethode.

3.3.4.1 Vergleich der Gesamtleistung bei adaptivem Modellwechsel und Ensemble-Modellierung

Die folgende Abbildung zeigt einen Vergleich von Adaptive Model Switching (AMSG1, AMSGN, AMSMLP) und Ensemble Modeling (EMLR, EMMLP, EMWAF) mit einem der besten Basismodelle (PAR). Der Vorteil solcher Methoden besteht darin, dass sie die Vorteile aller Modelle kombinieren können und somit eine stabilere Leistung im Laufe der Zeit bieten. Dies liegt daran, dass sie zu einem bestimmten Zeitpunkt unter den besten Basismodellen oder Kombinationen davon auswählen. So können wir die Vorhersagegenauigkeit in Zeiten verbessern, in denen noch keine ausreichende Datenmenge vorliegt und einige Modelle noch nicht ausreichend trainiert wurden.




Abbildung 16 Laufender durchschnittlicher RMSE der vorgedungen Lastprognosemethoden über einen Zeitraum von einem Jahr (vom 01.01.2016 bis 31.12.2016)

Ein weiterer Vorteil solcher Ansätze ist die Tatsache, dass Modelle verschiedener Gebäude kombiniert werden können, um größere Datensätze und eine bessere Generalisierung der Modelle zu nutzen.

3.3.4.2 Prognoseergebnisse der auf kausaler Inferenz basierenden Modellierung

In diesem Abschnitt stellen wir die Bewertung der Leistung des Modellierungsansatzes für kausale Inferenzen vor, der auf einer Verallgemeinerung der IOHMM-Modelle basiert, die in Auf Kausal-Inferenz

basierende Lastprognosen vorgestellt wurden. Insbesondere haben wir jeden Tag in 4 Intervalle von je 6 Stunden unterteilt. Für jedes dieser Intervalle haben wir 2 mögliche (versteckte) Zustände pro Intervall betrachtet. Mit anderen Worten, wir nehmen indirekt an, dass pro Intervall bis zu 2 verschiedene Muster/Profile auftreten können. Dies ist natürlich eine Annahme, die nur in der Praxis und durch Experimente mit einer unterschiedlichen Anzahl von verborgenen Zuständen überprüft werden kann. Die folgende Abbildung zeigt die Vorhersagen und auch den laufenden durchschnittlichen relativen RMSE auf der Grundlage der verallgemeinerten IOHMM-Modellierung im Vergleich zu Persistenzmodellen (N-same-days und N-days). Insgesamt lässt sich feststellen, dass die Leistung des verallgemeinerten IOHMM-Modells deutlich besser ist als die des N-same-days-Modells und nahe genug an das N-days-Modell heranreicht. Die Genauigkeit wurde hier für die Vorhersagen für den nächsten Tag bewertet. Wir sollten eine weitere Verbesserung erwarten, wenn wir die stündlichen Vorhersagen betrachten, da dieses Modell darauf trainiert ist, auch Übergangsphänomene (Muster) zwischen den Intervallen zu erfassen.




Abbildung 37 Relativer RMSE von Generalized IOHMM bei Day-Ahead-Vorhersagen und Vergleich mit Persistenzmodellen.

3.3.5 Validierungstests

Die Validierungsphase wurde auf der Serverinfrastruktur von Serve-U durchgeführt, wo Energieverbrauchsdaten von mehr als 140 Gebäuden verfügbar waren. Die Validierung der Vorhersagetechniken umfasste mehrere vorbereitende Schritte, zu denen in erster Linie die Entwicklung einer Datenverarbeitungspipeline gehört, die die Automatisierung des Modelltrainings, der Auswahl und der Inferenz ermöglicht. Die Datenverarbeitungspipeline umfasst insbesondere die folgenden Schritte:

1. Simulation der entwickelten Modelle auf einem lokalen Server. Nutzung der Daten eines Jahres für die Baugemeinde Wels, Oberösterreich;
2. Auswahl der effizientesten Modelle und deren Trainingstechniken;
3. Implementierung einer Reihe von effizienteren Modellen auf dem Plattformserver;
4. Implementierung und Pflege von JSON-Formaten für Daten, die über die API an die Trainings-/Inferenzmethoden der Modellklasse übergeben werden;
5. Anpassung von Modellen für die Arbeit mit Gebäudedaten, die mit einem bestimmten Code identifiziert wurden – GUID;
6. Implementierung einer Pipeline für die Verarbeitung von Daten zum Training `on_training_request` und zur Vorhersage `on_inference_request`;
7. Sequentielle Verarbeitung von Abfragen, die den Messverlauf für Trainingsmodelle enthalten, die für jedes Gebäude einzeln angegeben werden;
8. Berechnung der Vorhersagegenauigkeit anhand des RMSE-Maßes;

9. Anpassung oder Korrekturen der Modelle (falls erforderlich).




Abbildung 15 Schema der Datenverarbeitungspipeline für die Validierung unter realen Betriebsbedingungen

Zu den Vorhersagemodellen, die wir bei unseren Validierungstests verwendet haben, gehören die Persistenzmodelle für N-Tage und N-gleiche Tage, das PAR und das PARE. Wir haben diese Modelle aufgrund ihrer robusten Leistung und ihrer minimalen Berechnungsanforderungen ausgewählt. Außerdem haben die Modelle PAR und PARE bei den Simulationstests die beste Leistung gezeigt. Die Validierungstests wurden in Day-Ahead-Prognosen durchgeführt, da die Stromverbrauchsdaten nur am Ende eines jeden Tages verfügbar waren.

Die Python-Bibliothek Sklearn wurde zum Trainieren der Modelle verwendet, ebenso wie ein maßgeschneiderter RLS-Algorithmus (Recursive-Least-Squares) zum Online-Training der Modelle PAR und PARE. Das RLS-basierte Training zeigt eine etwas bessere Leistung, da es weniger Rechenressourcen benötigt. Über einen Zeitraum von zwei Wochen wurden automatisierte Genauigkeitstests durchgeführt und eine vergleichende Analyse anhand der RMSE-Metrik vorgenommen. Die Leistungsergebnisse sind in den folgenden Abbildungen dargestellt.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

e9942c19-b372-5618-845c-68d6fb5cf876	pkl	0744e8f8-5b0a-5f67-b3fe-f0c81c9200b6	csv
66e44cbc-a17a-5241-9a41-e827cf133ffd	pkl	18a2e549-4c1d-5c06-89f8-8c605bf97b86	csv
fa0a4b6f-75b2-5a81-9ffc-b2af58818286	pkl	209a97f3-5521-5377-9254-34b20ae2da05	csv
5688a868-4843-54f7-9d6d-501e5d5d4116	pkl	27322245-7f1e-55fb-a296-5bed0d8bbb42	csv
329d5fa7-03cb-56f7-8c48-2d4eccbe9ad6	pkl	2b28afba-a440-5adc-abc0-09013f62ae6f	csv
98729601-f8b4-53ca-954f-0485fe71cd31	pkl	2f33a5dc-78ff-5a45-bde1-ebc1599886a0	csv
6b4f5416-57a0-5e0e-95a0-384cfec54874	pkl	310058ed-6ea6-56a2-be54-b0a8dba30e0c	csv
18a2e549-4c1d-5c06-89f8-8c605bf97b86	pkl	329d5fa7-03cb-56f7-8c48-2d4eccbe9ad6	csv
2f33a5dc-78ff-5a45-bde1-ebc1599886a0	pkl	373b4d68-160b-5126-9b17-fa2a4dcbd66a	csv
c8c38f4a-a2cf-55da-87dd-06e76196c1fb	pkl	42431ab7-76e8-5ef4-b345-bbd129ea77a7	csv
4974b598-dc99-5608-883a-d0a3f8a30fea	pkl	45435251-0ffc-5857-b77e-6c127f8ab938	csv
98071f55-b7b6-5ffa-be29-c855aae392d6	pkl	4974b598-dc99-5608-883a-d0a3f8a30fea	csv
f7ea195f-e99d-5bc4-a711-df9a3eccae48	pkl	4c4a695d-ace5-5752-91a2-c8ece7cc6c72	csv
4c4a695d-ace5-5752-91a2-c8ece7cc6c72	pkl	50ab62a6-f693-507c-b9a1-c93aca29cdad	csv
8caf222c-7830-5b3b-a572-12608b65c111	pkl	510965a1-64a8-46e3-a098-fa00b24b8ff5	csv
7c235115-4c38-58bf-8430-abf609226983	pkl	53202aa4-7b10-54e6-9977-b6af02447b30	csv
53202aa4-7b10-54e6-9977-b6af02447b30	pkl	558fee82-9f14-521c-91b7-27e01921067d	csv
373b4d68-160b-5126-9b17-fa2a4dcbd66a	pkl	5688a868-4843-54f7-9d6d-501e5d5d4116	csv
42431ab7-76e8-5ef4-b345-bbd129ea77a7	pkl	59e5c636-3677-5ff9-9ebe-f3f406012ed5	csv
310058ed-6ea6-56a2-be54-b0a8dba30e0c	pkl	66e44cbc-a17a-5241-9a41-e827cf133ffd	csv
9fb22e29-705a-520e-9dc4-7d61e122939c	pkl	69d2740a-bdc2-563c-a09e-4ba0cc31bfe5	csv
209a97f3-5521-5377-9254-34b20ae2da05	pkl	6b4f5416-57a0-5e0e-95a0-384cfec54874	csv
f431186c-7105-58ca-be54-d5e56cce9ee4	pkl	7c235115-4c38-58bf-8430-abf609226983	csv
50ab62a6-f693-507c-b9a1-c93aca29cdad	pkl	81452abb-934c-50f8-94e6-4d58926bfd05	csv
69d2740a-bdc2-563c-a09e-4ba0cc31bfe5	pkl		

Abbildung 38 Beispiel für eine Liste von trainierten Modellen und Modellgewichtungsdateien für Gebäude mit bestimmten Identifikatoren




Abbildung 39 Beispiel für die Schätzung der Genauigkeit und der Belastungsvorhersagen bei vorher trainierten Modellen




Abbildung 40 Beispiel für die Schätzung der Genauigkeit und der Belastungsvorhersagen bei modifizierten Modellen

Wir sehen, dass die Genauigkeit der Vorhersagemodelle für alle Gebäude recht gut ist. In den meisten Fällen erzielten die Modelle PAR und PARE die beste Leistung, was auch in unseren Simulationstests der Fall war.

3.4 AP5: Smart Energy Service mit integrierter Datenqualitätsüberwachung und -verbesserung

Es wurden zu Beginn bei Diskussion mit Projektpartner und Energiegemeinschaften Anforderungen an die Benutzung der Serve-U-App gesammelt. Basierend auf diesen wurde die Benutzeroberfläche entwickelt. Außerdem wurde nach den ersten Validierungen eine Nutzer:innen-Befragung sowie ein Workshop durchgeführt, in welchen die Wünsche und Anmerkungen der Nutzer:innen hinsichtlich der Oberfläche erfasst und sofern möglich umgesetzt wurden. Diese Iteration führte zu einer deutlichen Verbesserung der Usability und Nutzung des Service. Das hier dargestellte Frontend greift auf die in Kapitel 2.4 beschriebene Daten-, Datenaufbereitungs-, Datenbank- und Kommunikationsstruktur zurück. Die folgenden Sektionen beschreiben die einzelnen Features der Nutzer:innen-Oberfläche im Detail.




Abbildung 41 Tab Home

Home

Abbildung 41 zeigt den Startbildschirm der App. Dieser ist unmittelbar nach dem Öffnen der App sichtbar und zeigt fasst die wichtigsten Informationen zusammen. Dazu zählt eine grafische Visualisierung der Energieprognose des Haushaltes für den folgenden Tag sowie eine Auflistung an anstehenden Aktionen.

Aktionen

Im Aktions-Tab (Abbildung 43) sind Aktionen sichtbar, die vom System vorgeschlagen wurden. Beim Anklicken einer Aktion werden weitere Details sichtbar. In dieser Ansicht können Endnutzer:innen Feedback über die geplante und tatsächliche Durchführung von Aktionen geben. Ein Formular in dieser Ansicht erlaubt es User:innen außerdem Feedback zu den Aktionen oder zur App im Allgemeinen an das Team des Forschungsprojektes zu senden.

Prognose

Der Prognose-Tab (Abbildung 44) zeigt eine Visualisierung der prognostizierten Energiedaten für den darauffolgenden Tag. Dabei wird unterschieden zwischen Daten für einen Haushalt und für die gesamte Community. Beim Haushalt beinhaltet dies den Energieüberschuss, Netzbezug und die Erzeugung (sofern Erzeugungsdaten in das System eingespeist werden). Für die Community wird die Summe aller Einspeisungen der Summe aller Netzbezüge gegenübergestellt. Dies gibt Anwender:innen die Möglichkeit, visuell Zeiten mit hohem Energieüberschuss in der Community zu identifizieren. Zusätzlich werden Aktionszeiträume in der Grafik visualisiert. Zahlenwerte können durch einen Click auf die Balken im Diagramm eingeblendet werden.

Historisch

In diesem Tab (Abbildung 44) können historische Energiedaten abgerufen werden. Standardmäßig werden die Energiedaten vom Vortag angezeigt, sofern diese bereits im System verfügbar sind, der Zeitraum kann jedoch benutzerdefiniert konfiguriert werden. Die Visualisierung der Daten ist äquivalent zum Prognose Tab umgesetzt.

Community

Der Community-Tab (Abbildung 45) wurde entwickelt, um Nutzer:innen der App ein größeres Zugehörigkeitsgefühl zu ihrer Community zu geben und sie zum regelmäßigen Nutzung der App anzuregen. Darin enthalten ist eine Rangliste der Teilnehmer. Diese erhalten Punkte für Aktivität in der App. Darunter ist eine Kommentarsektion, welche es Teilnehmer:innen ermöglicht, sich untereinander auszutauschen. Außerdem kann diese für Mitteilungen des Entwicklerteams an die Community genutzt werden. Die angezeigten Bildschirmnamen und Profilbilder können von Anwender:innen selbst konfiguriert werden (sh. Abbildung 46).



Abbildung 42 Tab Aktionen

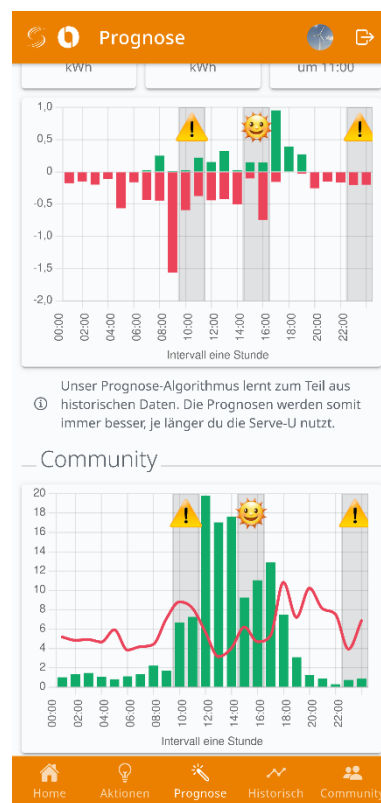


Abbildung 43 Tab Prognose




Abbildung 44 Tab Historisch




Abbildung 45 Tab Community

Abbildung 46 Profil Einstellungen

3.5 AP6: Entwicklung des Systemoptimierungsmodells

Im folgenden Unterkapitel werden die Ergebnisse einer Simulationsstudie dargestellt. Diese hatte primär zum Ziel die Funktionalität des Algorithmus zu beweisen, bevor dieser im Feld eingesetzt wurde. Intensive Simulationsstudien wurden aufgrund des frühen Übergangs auf Funktionsvalidierungen im Feld nicht weiterverfolgt.

3.5.1 Ergebnisse der Simulationsvalidierung

Das Ergebnis des Optimierungsprozesses stellt das Gerät und den Einschaltzeitpunkt dar, der dann zu lesbarem Text weiterverarbeitet wird. Es werden Methoden zum Umgang mit den Restriktionen von MILP und der Implementierung von Wahrscheinlichkeiten sowie Unsicherheiten in dem speziellen Problem der direkten Interaktion mit Menschen entwickelt.

Erste Simulationen des beschriebenen Ansatzes wurden durchgeführt. Die folgenden Ergebnisse beziehen sich auf eine Gemeinschaft bestehend aus 6 Prosumern (mit PV-Anlage) und 3 Consumern. Es wurden perfekte Prognosen und eine Erfüllungswahrscheinlichkeit der Empfehlungen von 1 angenommen. Abbildung 47 zeigt die Leistungsflüsse innerhalb der Gemeinschaft sowie die Leistungsflüsse in einem Beispielhaushalt.




Abbildung 47: Leistungsflüsse in der Geimeinschaft und exemplarischer Haushalt sowie die Lastverschiebung (dunkelrot) für einen Tag im Juni

Die dunkelrote rechteckige Linie im unteren Teil der Grafik zeigt zwei unterschiedliche verschiebbare Lasten mit vereinfachten Profilen. Eines davon soll um 5:45 Uhr und das zweite um 13:45 gestartet werden.

Diese vorläufigen Ergebnisse sind jedoch nicht repräsentativ und beziehen sich nur auf die angenommene Energiegemeinschaft. Trotzdem lassen sie auf ein hohes Potential einer Verbrauchsanpassung durch eine derartige Lastverschiebung in Energiegemeinschaften schließen.

Um diese ersten Ergebnisse vergleichbar zu machen, wurden 3 unterschiedliche Szenarien betrachtet. Diese sind (1) keine Energiegemeinschaft, (2) Energiegemeinschaft ohne Optimierung und (3) optimierte Energiegemeinschaft.

Tabelle 20: Vorläufige Simulationsergebnisse

Szenario (1 Tag)	Gesamtkosten in €
keine Energiegemeinschaft	12.83
Energiegemeinschaft ohne Optimierung	7.29
optimierte Energiegemeinschaft	5.49

Mit den angenommenen Tarifen würden durch eine einfache Energiegemeinschaft die Gesamtkosten um 43 % wohingegen durch die Optimierung sogar eine Reduzierung um 57 % erreicht werden kann.

3.6 AP7: Funktionsvalidierung / Business Case: Digitale Energiegemeinschaften

Es wurde ein Kriterienkatalog zur Funktionsvalidierung entworfen. Der Kriterienkatalog umfasst Kriterien zu Akquirierung und Engagement von Nutzer:innen, Voraussetzungen und User Experience. In der Diskussion der Kriterien wird deutlich, dass die Akquise und Aktivierung von potenziellen Testnutzer:innen bereits in der Frühphase der Validierung des vorliegenden Konzeptes von Bedeutung sind. Die Zielgruppe

sollte strategisch ausgewählt werden. Die gewählte Kommunikation und Ansprache sollten im Einklang mit der zu erreichenden Zielgruppe stehen.

Die niederschwellige Nutzung der serve-U App wird durch verschiedene Voraussetzungen beeinflusst, wobei sowohl technische als auch sonstige Faktoren die Niederschwelligkeit des Konzepts beeinflussen. Technisch gesehen erfordert die App lediglich einen Smartmeter und Internetzugang, während zusätzliche Anforderungen, wie das Verständnis über das Bedienen der Messinfrastruktur, potenziell die Zugänglichkeit beeinträchtigen können und eine intensive Betreuung seitens des Projektteams erfordern. Nicht zuletzt nimmt auch die User Experience Einfluss auf die Plausibilität und Validität des vorliegenden Funktionsmodells. Dabei sind z.B. die Projektziele und Nutzer:innenbedürfnisse in Einklang zu bringen. Zudem ist in der Gestaltung der App auf eine leicht lesbare und intuitive Informationsarchitektur zu achten, sodass eine Niederschwelligkeit in der Nutzung der App erreicht werden kann.

Die Nutzer:innenakquise und die Durchführung der Funktionsvalidierung mit den Testnutzer:innen konnte erfolgreich durchgeführt werden. In den veranstalteten Co-Creation-Workshops wurde Feedback zum vorliegenden Tool eingeholt und konnte teilweise bereits im Tool eingearbeitet werden. Der Anwendungsfall für das Funktionsmodell sind Energiegemeinschaften. Um diese adäquat auf ihre Funktionalität testen zu können und verwertbare Ergebnisse zu bekommen, wurden zwei Hypothesen aufgestellt und getestet:

Für eine erfolgreiche Implementierung der serve-U App in Energiegemeinschaften ...

1. ... ist es essenziell, geeignete Testnutzer:innen bereits in der Entwicklung der App einzubinden, um das innovative Optimierungstool bedürfnisangepasst gestalten zu können.
2. ... ist die User-Experience (UX), z.B. Produktziele vs. Nutzer:innenbedürfnisse, Oberfläche der App, Informationsarchitektur und Gamification, ein entscheidender Faktor.

Mit der Elektrizität-Richtlinie 2019/944 sowie Erneuerbare-Energie-Richtlinie 2018/2001 wurden die Bürger:innen von der EU-Kommission in den Mittelpunkt einer demokratischen Energiewende gestellt. Vor diesem Hintergrund sind Bürgerinnen und Bürger als zentrales Element einer demokratischen und sozialen Energiewende anzusehen sowie ihnen die Verantwortung zuzugestehen, sich aktiv am Energiemarkt zu beteiligen. Dabei hat die Implementierung des Funktionsmodells der serve-U App einen wichtigen Beitrag geleistet.

Das Hauptziel des vorliegenden Funktionsmodells ist es, dass Nutzer:innen mithilfe der serve-U App neue Gewohnheiten im Umgang mit Strom erlernen können. Damit dieses Ziel erreicht werden kann, muss das innovative Tool bedürfnisangepasst gestaltet werden. Es erwies sich als adäquate Herangehensweise, interessierte Testnutzer:innen, die gleichzeitig auch als Co-Entwickler:innen fungierten, bereits in die Entwicklung der App einzubinden.

Durch das Feedback und die Anregungen der teilnehmenden Personen konnten Verbesserungen sowohl im Implementierungsprozess als auch an der App selbst vorgenommen werden. Dies zeigt, dass unbedingt am Weg, Bürger:innen in (Innovations-)Prozessen aktiv zu beteiligen, festgehalten und in weiteren Projekten verstärkt umgesetzt werden sollte.

Anknüpfungspunkt für weitere Forschungen bietet die Diversifizierung der teilnehmenden Personen. Dabei ist die Frage zentral, wie kann eine breitere Zielgruppe angesprochen werden, sodass Funktionsmodelle entworfen werden können, die für eine breite Bevölkerungsgruppe nutzbar und hilfreich ist. Die Diversität soll sich dabei in sozio-ökonomischen Kriterien äußern.

3.6.1 Handlungsempfehlungsmatrix

Die „derzeitige Lösung“ der Handlungsempfehlungsmatrix (Tabelle 21) bezieht sich auf den zuvor beschriebenen Fall der Analogen Energiegemeinschaft.

Tabelle 21: Handlungsempfehlungsmatrix

Problem	Derzeitige Lösung	Serve-U
Visualisierung	• Erzeugte Energie wird von einem Datenlogger erfasst • Visualisierung von Verbrauchermustern nur schwierig möglich	• Historischen und aktuellen Erzeugungs- und Verbrauchsdaten werden visualisiert • Visuelle Wiedergabe von Verbrauchsmustern
Monitoring	• Keine Prognosen möglich • Keine Handlungsempfehlungen • Erzeugungsdaten können von dem Datenlogger entnommen werden	• Übersicht der nächsten 24-72 Stunden • Handlungsempfehlungen für die nächsten 24-72 Stunden • Historische sowie aktuelle Daten vorhanden
Energiefluss-optimierung	• Durch hohe Eigeninitiative möglich • Keine Wetterdaten, Erzeugungsprognosen, etc. vorhanden • Vorausplanung nur schwierig möglich	• Optimierung durch bereitgestellte Daten möglich (Wetterdaten, Verbraucherdaten, Börsenkurs, ...) • Fahrplan für die nächsten 24-72 Stunden abrufbar
Kosten	• Niedrige Kosten • Wirtschaftliche Nutzung der Energie nur bedingt möglich	• Niedrige Kosten, da mit vorhandener Infrastruktur kompatibel • Keine Nachrüstung von Sensorik nötig • Hohe Eigenverbrauchsrate und bestmögliche Nutzung der Energie
Implementierung	• Je nach System unterschiedliche Möglichkeiten der Implementierung	• Kann mit bereits vorhandenen Smart-Meter und Wechselrichter verbunden werden • Mit nahezu jedem System kompatibel • Keine aufwändige Implementierung nötig • Implementierung sämtlicher Energieträger möglich, jedoch vorrangig PV-Anlagen • Open-Source-Charakteristik
Nutzerfreundlichkeit	• Daten Lokal abrufbar • Keine automatische Analyse der Daten	• Intuitive Bedienung • Informationen gesammelt auf einer App • Jederzeit und überall abrufbar • Gesammelte Energie und Verbrauchsdaten werden automatisch analysiert
Skalierbarkeit	• Je nach System unterschiedliche Möglichkeiten zur Erweiterung	• System kann problemlos erweitert werden • Problemlose Integration der Erweiterungen
Ressourcen	• Aktuelle Erzeugungsdaten	• Historische Daten • Aktuelle und Historische Wetter Daten • Börsen und Handels Daten

3.6.2 Berechnung der unterschiedlichen Business Cases

Die folgenden Tabellen zeigen eine theoretische Aufschlüsselung der Kostenrechnung der Business Cases, um die Wirtschaftlichkeit der jeweiligen Szenarien zu visualisieren. Um den monetären Nutzen für die Energiegemeinschaft übersichtlich darzustellen und einen Überblick zu geben welche voraussichtlichen Einsparungen ein Mitglied ohne und mit eigener PV-Anlage erreichen könnte. Die verbrauchte Energie aus PV-Anlagen (zum üblichen Marktpreis) und die Einnahmen von der Einspeisung ins Netz werden mitberücksichtigt. Neben den Tarifkosten für Abnahme und Einspeisung, spielen die Anzahl der Teilnehmer:innen, der jährliche Gesamtverbrauch und die Anzahl der für Lastverschiebungen geeigneten Verbraucher eine maßgebliche Rolle für die Wirtschaftlichkeit der Serve-U Plattform. Für die genaue Berechnung der Wirtschaftlichkeit dienen in späterer Folge die Ergebnisse der Funktionsvalidierung.

In den folgenden drei Geschäftsmodellen (Analoge-, Nutzerinduzierte-, und Automatisierte Energiegemeinschaft) wird tabellarisch dargestellt welche monetären Vorteile das jeweilige Geschäftsmodell mit sich bringt. Den Ausgangspunkt bilden fünf Parteien mit PV-Anlage und fünf Parteien ohne PV-Anlage. Des Weiteren wird in zwei Kategorien unterschieden, einerseits in einer Energiegemeinschaft und einmal ohne Energiegemeinschaft.

Es wurde ein geringer gemeinschaftsinterner Strompreis von 9 ct/kWh, ein Einspeisetarif von 7,6 ct/kWh und ein geringer Gesamtbezugspreis von 17,279 ct/kWh angenommen. Die stark steigenden Endkundepreise seit Beginn 2022 wurden in der Berechnung nicht berücksichtigt.

Mitglieder mit einer PV-Anlage beziehen jeweils 5% aus der Energiegemeinschaft (EG) und je nach Geschäftsmodell 30%-47% aus der vorhandenen PV-Anlage. Wohingegen Parteien ohne PV-Anlage auf die produzierte Energie der EG zurückgreifen, da selbst keine Erzeugt wird. Hier beläuft sich der Anteil zwischen 20%-34% je nach Geschäftsmodell.

3.6.2.1 Analoge Energiegemeinschaft

	Mit PV-Anlage (5 Parteien)	Ohne PV-Anlage (5 Parteien)
Ohne Energiegemeinschaft		
Gesamtjahresverbrauch (kWh)	22500	22500
Direktverbrauch PV-Betreiber	30%	-
Nettobezug (kWh/a)	14250	22500
Stromkosten für Netzbezug (€/a)	2462,23	3888,00
Erlöse durch Netzeinspeisung (€/a)	1463,00	-
Stromkosten abzüglich Erlöse (ohne EG, €/a)	999,23	3888,00
Mit Energiegemeinschaft		
Bezug aus EG (%)	5%	20%
Bezug aus EG (kWh/a)	1375	5500
Netzbezug nach EG-Handel	12875	1700
Gesamtkosten mit EG (abzüglich Erlöse bei PV-Betreiber, €/a)	837,98	3627,72
Ersparnis durch EG (€/a)	161,25	260,01
Ø Ersparnis pro Teilnehmer (€/a)	32,25	52

3.6.2.2 Nutzerinduzierte Energiegemeinschaft

	Mit PV-Anlage (5 Parteien)	Ohne PV-Anlage (5 Parteien)
Ohne Energiegemeinschaft		
Gesamtjahresverbrauch (kWh)	22500	22500
Direktverbrauch PV-Betreiber	40%	-
Netto Bezug (kWh/a)	11500	22500
Stromkosten für Netzbezug (€/a)	1987,06	3888,00
Erlöse durch Netzeinspeisung (€/a)	1254,00	-
Stromkosten abzüglich Erlöse (ohne EG, €/a)	733,06	3888,00
Mit Energiegemeinschaft		
Bezug aus EG (%)	5%	27%
Bezug aus EG (kWh/a)	1375	7425
Netzbezug nach EG-Handel	10125	15075
Gesamtkosten mit EG (abzüglich Erlöse bei PV-Betreiber, €/a)	544,86	3536,71
Ersparnis durch EG (€/a)	188,20	351,02
Ø Ersparnis pro Teilnehmer (€/a)	37,64	70,20

3.6.2.3 Automatisierte Energiegemeinschaft

	Mit PV-Anlage (5 Parteien)	Ohne PV-Anlage (5 Parteien)
Ohne Energiegemeinschaft		
Gesamtjahresverbrauch (kWh)	22500	22500
Direktverbrauch PV-Betreiber	47%	-
Netto Bezug (kWh/a)	9575	22500
Stromkosten für Netzbezug (€/a)	1654,45	3888,00
Erlöse durch Netzeinspeisung (€/a)	1107,70	-
Stromkosten abzüglich Erlöse (ohne EG, €/a)	546,75	3888,00
Mit Energiegemeinschaft		
Bezug aus EG (%)	5%	34%
Bezug aus EG (kWh/a)	1375	9350
Netzbezug nach EG-Handel	8200	13150
Gesamtkosten mit EG (abzüglich Erlöse bei PV-Betreiber, €/a)	331,59	3445,71
Ersparnis durch EG (€/a)	215,15	442,02
Ø Ersparnis pro Teilnehmer (€/a)	43,03	88,40

3.6.3 Wettbewerbsanalyse

3.6.3.1 Switchboard [14]

Switchboard ist ein deutsches Unternehmen mit Sitz in Stuttgart. Neben den Geschäftsführer:innen Nico Bovelette und Estonia Hoffmann, hat das im Jahr 2021 neu gegründete Unternehmen aktuell noch neun weitere Mitarbeiter:innen. Switchboard hat sich spezialisiert auf Programmierschnittstellen (kurz APIs) und bietet seinen Kund:innen die Möglichkeit sich mit Drittanbieter:innen von Energieservices via API (Application Programming Interface) auf deren eigenen Plattform zu verbinden. Ziel des jungen Startup Unternehmens ist es in einem komplexen Energiemarkt als Marktplatz zu fungieren und dabei gleichzeitig die Energiewende voranzutreiben.

API-Produkte

Produkt	Funktionsbeschreibung	Status
Photovoltaik-Erzeugungsprognose	Erlaubt die Erzeugungsprognose für die nächsten Tage, ohne über Messeinrichtungen oder anlagenspezifische Erzeugungsdaten zu benötigen.	Verfügbar
Haushaltsstromlastprognose mit Verbrauchsmessung	KI-unterstützte Verbrauchsprognose, basierend auf historischen Verbrauchsmessungen.	geplant
Netzentgeltrechner	Erlaubt Verbrauchsberechnung von Netzentgelten im Strom- und Gassegment für Kund:innen mit Standardlastprofil oder registrierender Leistungsmessung.	geplant
OCR Bilderkennung	Erlaubt das Umwandeln von Bildern und Dokumenten in PDFs.	geplant
Wetterprognose Deutschland	Bietet Vorhersagen auf Oberflächenebenen oder in einer gewissen Höhe/Tiefe. (Temperatur, Luftfeuchtigkeit und unterschiedliche Strahlungswerte)	geplant
Netzentgelte Strom und Gas	Tagesaktuelle Berechnung von Netzentgelten für Strom und Gas.	geplant
Ortsinformation Strom und Gas	Das Produkt erlaubt tagesaktuelle und stichtagsbezogene Ermittlung zu Lokationen für Strom und Gas.	geplant
Tarife Strom und Gas	Ermöglicht tagesaktuelle Berechnung von Tarifen von Haushalts- und Gewerbekund:innen sowie der zugehörigen Preisbestandteile für Strom und Gas.	geplant
Unternehmensinformation Strom und Gas	Tagesaktuelle Erhebung von Unternehmensdaten für die Medien Gas und Strom.	geplant
MaLo Identifikation (AI)	Sortiert, bewertet und identifiziert Marktllokationen im System und erlaubt eine automatische Zuweisung oder Ablehnung von Klärfällen.	geplant

Photovoltaik- Erzeugungsprognose

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Ohne eigene Messung ermöglicht die PV-Erzeugungsprognose, den Viertelstundenertrag einer Photovoltaikanlage zu prognostizieren. Produktionsabmessungen der PV-Anlage sind dazu nicht nötig. Basierend auf Anlagendetails, wie Dachausrichtung und –neigung, sowie der Verwendung aktueller Wettervorhersagen am Anlagestandort, werden Erzeugungsprognosen erstellt. Für die Berechnung der zu erwarteten Energiemenge werden die Produktionsdaten vergleichbarer Anlagen verwendet.

Vorteile

- Keine Speicherung und Übertragung von Kundendaten notwendig
- Innovative und intelligente Weiterentwicklung des Kundenprodukts
- Zugang zu Know How eines großen Energieversorgers
- Funktioniert in EU-Cloud

Funktionsprinzip



Abbildung 48: Switchboard, Funktionsprinzip

Preise

Plan	Funktionsbeschreibung	Preis	Status
Starter	Vorhersagezeitraum: 24h Wettervorhersage: 1x täglich	€29.00 /Monat	geplant
Professional	Vorhersagezeitraum: 24h Wettervorhersage: alle 6 Std.	€239.00 /Monat	geplant
Premium	Vorhersagezeitraum: 48h Wettervorhersage: alle 3 Std.	€399.00 /Monat	geplant
Enterprise	Maßgeschneidertes Angebot wird erstellt		verfügbar

3.6.3.2 Venios

Die 2012 gegründete Venios GmbH mit Hauptsitz in Frankfurt am Main und einer Niederlassung im österreichischen Hartberg versucht Energienetzbetreiber:innen eine Plattform zur Netzüberwachung bereit zu stellen.

Diese offene Softwareplattform soll eine Netzüberwachung und -steuerung in Echtzeit ermöglichen und für alle beteiligten im Netzbereich eine Erleichterung darstellen. Des Weiteren ermöglicht diese Software eine raum-zeitliche Analyse von elektrischen Energiesystemen.

Venios Energy Plattform[15]:




Abbildung 49: Veniso Energy Plattform

Effiziente Planung

- Intuitive Anlagenanschlussrechnung: einfaches Handling, präziser Output
- Netzengpässe: frühzeitiges Erkennen und intelligentes Handeln
- Asset Manager: Ableitung von Handlungen aus aktuellen Zuständen

Wertvolle Prognosen

- Lastprognosen für den nächsten Tag
- Netzzustandsprognosen: Früherkennung von Engpässen
- Szenariengenerierung: Erstellung von „Was wäre wenn“ Netzsituationen

Intelligente Steuerung

- Flexibilitäten optimiert ansteuern
- Regelbare Ortsnetz Trafos für Spannungsniveaueanpassung
- Steuerung von E-Mobilität Ladesäulen mit Intelligenz und Betreiberprognosen

3.6.3.3 SMA Solar Technology AG

Die 1981 in Niestetal (Deutschland) gegründete SMA Solar Technology AG ist ein führender Anbieter von Komponenten für die Erzeugung von EE. Mit über 3000 Mitarbeitern in 18 Ländern ist SMA ein global agierendes Unternehmen. Im Jahr 2020 wurde ein Umsatz von 1,026 Mrd. Euro erwirtschaftet. Die vorschreitende Digitalisierung erreicht auch die Photovoltaik und Energiewirtschaft. SMA ist darin bemüht Photovoltaik mit Speichern, E-Mobilität und weiteren Sektoren zu vernetzen und in ein gesamtheitliches System zu integrieren.

Sunny Home Manager 2.0

- Wetterprognose mit Hilfe von Internetdaten und Anpassung an lokale Gegebenheiten
- Vernetzung mit Haushaltsgeräten, Batteriespeicher, E-Fahrzeug und PV-Anlage
- Übernimmt die Steuerung aller Energieflüsse, sobald diese dem System bekannt sind




Abbildung 50: Sunny Home Manager 2.0 Oberfläche[16]: Sunny Home Manager 2.0 Oberfläche[16]

3.6.3.4 Smappee

Smappee wurde 2012 von Stefan Grosjean und Hans Delabie gegründet. Die Firmenzentrale ist in einem energieneutralen Gebäude namens "Snowball" in Harlbeke, Belgien beheimatet. Die Firma entwickelt Systeme zur Überwachung und Verteilung von Energie (Strom, Wasser, Gas, ...). Mit fünf Vertretungen in Australien, USA, dem Nahen Osten, England und Süd Afrika sind die Schlüsselmärkte von Smappee abgedeckt.

Smappee Infinity [17]

- Cloud-basiertes Interface
- App und Dashboard
- Echtzeitdaten
- Dynamischer Lastausgleich zwischen PV, E-Fahrzeug und anderen Geräten
- Solar, Gas, Energie und Wasser auf einen Blick
- Mit IoT-Produkten und Dienstleistungen kompatibel

3.6.3.5 Fronius

Fronius, 1945 gegründet, ist ein österreichisches Traditionsunternehmen und in den Bereichen der Solarenergie, Schweiß- und Ladesysteme tätig. 1992 wurde von Fronius der Grundstein für den Bereich Solarenergie gelegt und stätig vorangetrieben. Das Portfolio umfasst Smart Meter, Speicherlösungen und weitere Produkte. Der Fronius Ohmpilot ist einer dieser Produkte. Dieser kann über den Fronius Wechselrichter automatisiert angesteuert werden und ermöglicht daher eine effizientere Nutzung des nachhaltig erzeugten Stroms. Der Ohmpilot kann z.B. mit einem Heizstab im Boiler oder Infrarotpaneelen verbunden werden und diese ansteuern. Eine weitere Option, um die Effizienz zu steigern bietet, sofern ein E-Auto vorhanden, die Wallbox (oder auch Fronius „Wattpilot“ genannt). Diese wird, genauso wie der Ohmpilot, über den Wechselrichter automatisiert angesteuert. Desweiteren wird auch eine webbasierende Lösung zum Monitoring und zur Analyse der erzeugten Energie angeboten.

Fronius Solar.Web

- Überwachung und Analyse von Photovoltaik-Daten
- Reports und Benachrichtigungen
- Fern-Update Funktion (Wechselrichter)
- Visuelle Darstellung des Verbrauchs und der Produktion *

Fronius Solar.Web Premium (Kostenpflichtig)

- Alle Vorteile von Solar.Web
- Produktions- und Verbrauchskurven auf Tagesbasis *
- Individuelle Reports jederzeit abrufbar
- Darstellung der PV-Rentabilität *
- Ertrags- und Kostenübersicht *
- Vorhersage der PV-Produktion (48 Stunden)
- Umfangreiche Wetteranzeige
- Datenabfrage per Amazon Alexa

* nur mit Fronius Smart Meter möglich

3.6.4 Ergebnisse der Funktionsvalidierungsphase – Potentialanalyse

Der beschriebene Ansatz wurde in zwei Feldversuchen mit mehreren Energiegemeinschaften getestet und die Ergebnisse publiziert [18]. Die Teilnehmer erhielten Lastverschiebungsempfehlungen, welche mithilfe des am Abend vor dem Tag der Empfehlung und konnten die Lastverschiebungsaktion nach dem Startzeitpunkt bestätigen oder ablehnen. Alle benötigten Messdaten, Prognosen und App-Interaktionen wurden über die Zeit der Feldtests hinweg in einer Datenbank aufgezeichnet. Diese Daten wurden im Anschluss dafür verwendet die Wirksamkeit der entwickelten Lösung zu bewerten. Speziell das Nutzer:innen-Feedback konnte später verwendet werden, um das realistische Potenzial dieses nutzerzentrierten Lastverschiebungsansatzes zu berechnen.

Die Ergebnisse der Optimierungsmethode wurden analysiert, um das Potenzial des beschriebenen nutzerzentrierten Lastverschiebungsansatzes in Energiegemeinschaften zu untersuchen. Es muss betont werden, dass diese Analyse weder den gemessenen Effekt auf die Lastprofile analysiert noch nachweist. In der folgenden Analyse wird davon ausgegangen, dass die Prognosen (für Last und Erzeugung) perfekt sind. Zudem wird angenommen, dass die vordefinierten Lastprofile der betrachteten Lastverschiebungsgeräte korrekt sind. Es wird auch angenommen, dass eine Lastverschiebungsaktion, sobald sie von einem Nutzer bestätigt wurde, korrekt ausgeführt wurde. Das einzige direkte Ergebnis aus dem Feldtest, das in die folgende Analyse einfließt, ist somit das Nutzer:innen-Feedback.

Die folgenden Ergebnisse beziehen sich auf eine Gemeinschaft, die aus 9 Prosumenten (mit PV-Anlage) und 14 Konsumenten besteht. Die Ergebnisse wurden für drei verschiedene Szenarien berechnet, die sich durch unterschiedliche Umsetzungsraten der Lastverschiebungsempfehlungen unterscheiden:

1. keine Optimierung / Empfehlung,
2. reale Umsetzung gemäß dem direkten Feedback der Nutzer aus den Feldtests und
3. perfekte Umsetzung, die das maximale Potenzial des Ansatzes darstellt.

Abbildung 51 zeigt die tägliche Eigenverbrauchsquote der betrachteten Energiegemeinschaft während des zweiwöchigen Feldtestzeitraums im November für verschiedene Szenarien. Aufgrund guter Wetterbedingungen und ausreichend installierter PV-Leistung gab es genug Überschussstrom, um den Verbrauch der Haushalte zu optimieren.




Abbildung 51: Eigenverbrauch der 3 beschriebenen Szenarien für Gemeinschaft 1 vom 2. bis 15. November 2023.

Während die blauen Balken das Standardszenario ohne Optimierung und Empfehlungen darstellen, beziehen sich die orangefarbenen Balken auf das Lastverschiebungspotenzial, das berechnet wurde, indem das tatsächliche User-Feedback aus dem Feldtest berücksichtigt wurde. Die gelben Balken zeigen das theoretische Potenzial, wenn alle Lastverschiebungsempfehlungen umgesetzt worden wären. Abbildung 52 und Abbildung 53 zeigen den Vergleich des Lastprofils zwischen den verschiedenen Szenarien für einen exemplarischen Haushalt an einem Tag (9. November).




Abbildung 52: Berechnetes theoretisches Lastprofil eines Haushalts, wenn alle Lastverschiebungsempfehlungen umgesetzt werden.




Abbildung 53: Berechnetes Lastprofil eines Haushalts mit den tatsächlich ausgeführten Lastverschiebungsempfehlungen.

Das Lastprofil ist unterteilt in Strom aus dem Netz (blaue Fläche) und Strom aus der Energiegemeinschaft (C2H, orangefarbene Fläche). Betrachtet man Load_{Opt}, so sieht man, dass von insgesamt drei Empfehlungen (Abbildung 52) nur eine („Energie sparen“) um ca. 20:00 Uhr umgesetzt wurde (Abbildung 53).

In Abbildung 54, Abbildung 55 und Abbildung 56 wird der potenzielle Effekt der verschiedenen Szenarien (Umsetzungsraten) auf die gehandelte Energie dieser Energiegemeinschaft am 9. November dargestellt.




Abbildung 54: Innerhalb der Energiegemeinschaft getauschte Leistung (C2H) und Überschussleistung (C2G) in der Energiegemeinschaft ohne Lastverschiebungsempfehlungen/Optimierung.




Abbildung 55: Innerhalb der Energiegemeinschaft getauschte Leistung (C2H) und Überschussleistung (C2G) in der Energiegemeinschaft mit den tatsächlich durchgeführten Lastverschiebungsempfehlungen.




Abbildung 56: Innerhalb der Energiegemeinschaft getauschte Leistung (C2H) und Überschussleistung (C2G) in der Energiegemeinschaft, wenn alle Lastverschiebungsempfehlungen umgesetzt werden.

Die verfügbare Energie innerhalb der Gemeinschaft wird aufgeteilt in die Energie, die von der Gemeinschaft an die Haushalte abgegeben wird (C2H, orange) und die überschüssige Energie, die von der Gemeinschaft ins Netz eingespeist wird (C2G, gelb).

3.6.4.1 Diskussion

Es ist in Abbildung 52 und Abbildung 53 zu beobachten, dass jede Empfehlung einen erheblichen Einfluss auf das Lastprofil eines Haushalts haben kann. Abbildung 54, Abbildung 55 und Abbildung 56 zeigen, dass obwohl am betrachteten Tag nur 9 von 40 (22,5 %) Empfehlungen akzeptiert wurden, der Einfluss auf das Lastprofil erheblich ist.

Wenn man den gesamten Zeitraum von zwei Wochen des vorgestellten Feldtests berücksichtigt, hat die vorgeschlagene Lösung das Potenzial, die Eigenverbrauchsquote deutlich zu steigern. **Im abgebildeten Zeitraum lag die Umsetzungsrate durchschnittlich bei 27 %, was zu einer Erhöhung der Eigenverbrauchsrate um etwa 11 Prozentpunkte führte.**

Wenn alle Empfehlungen umgesetzt werden, könnte die Eigenverbrauchsrate potenziell von 28,7 % auf 58,5 % (+29,8 %-Punkte) steigen und sich damit fast verdoppeln.

Beim Vergleich verschiedener Energiegemeinschaften wurde festgestellt, dass das Potenzial für Lastverschiebung stark von der Struktur der jeweiligen Gemeinschaft abhängt. Das Verhältnis zwischen Produktion und Verbrauch scheint ein guter Indikator dafür zu sein. Verhältnisse um eins haben das höchste Potenzial gezeigt.

Natürlich müssten umfassendere Feldstudien durchgeführt werden, um zuverlässige, messbare und allgemeingültige Informationen über den Nutzen des beschriebenen Ansatzes zu erhalten. Aber gemäß den erzielten Ergebnissen sieht das Potenzial für Lastverschiebung innerhalb von Energiegemeinschaften definitiv vielversprechend aus.

Es müssen Methoden zur Verbesserung der Prognosegenauigkeit entwickelt werden, die mit den Einschränkungen von MILP umgehen und Wahrscheinlichkeit sowie Unsicherheiten im speziellen Problem der direkten Interaktion mit Menschen berücksichtigen. Das Lernen aus den Nutzerreaktionen, um das Verhältnis zwischen empfohlener Lastverschiebung und tatsächlicher Lastverschiebung

auszugleichen, könnte bei der Entwicklung einer Strategie helfen, um die optimale Lastverschiebung zu erreichen.

Es gibt noch mehrere Fehlerquellen im beschriebenen Ansatz (Prognose, Optimierung, Annahmen zu Lastprofilen,...), die quantifiziert werden müssten, um zu bestimmen, welcher Grad an Präzision erforderlich ist.

Zudem sind die Prognosen unabhängig von der Optimierung. Rückkopplungen zwischen den Prognosen und dem Optimierungsergebnis werden als zukünftige Optionen diskutiert.

3.7 AP8: Netzstabilität / Regulierung / sozio-technologische Begleitforschung

3.7.1 Netzstabilität

Die Auswirkungen eines Konzeptes, wie es im vorliegenden Projekt untersucht wurde, auf die Netzstabilität, wurden im Deliverable 8.3 im Detail betrachtet. Erneuerbare-Energiegemeinschaften (EEGs) fördern lokal erzeugten Ökostrom durch geringere Netzentgelte. Untersuchungen zeigen jedoch, dass EEGs in Österreich bisher keinen verlässlichen netz- und systemdienlichen Beitrag leisten. Netz- und systemdienliche Beiträge entstehen hauptsächlich durch Einzelinitiativen, wie manuelle Verbrauchserhöhungen bei Sonnenschein.

Es ist fraglich, ob die Erhöhung des lokalen Verbrauchs zu Zeiten hoher Erzeugung ausreicht, um die Reduktion der Netzentgelte und Steuern zu rechtfertigen. Der Einsatz von Stromspeichern kann den Direktnutzungsanteil erhöhen, jedoch kommt es selbst bei hohem Direktnutzungsanteil zu hohen Einspeiseleistungen.

Andere Anreizmechanismen könnten besser geeignet sein, um Netz und Versorgungssystem gezielt und kosteneffizient zu entlasten. Eine gezielte Weiterentwicklung ist notwendig, um die Flexibilitätsnutzung unter Berücksichtigung verschiedener netz- und systemrelevanter Faktoren zu ermöglichen.

3.7.2 Methodik des D8.1 Withepaper: Empfehlungen für Anpassungen der regulatorischen Rahmenbedingungen

In Rechtsanalyse (siehe Anhang "Rechtsanalyse" M8.2)¹ wurden einerseits kurz die europäischen Grundlagen und andererseits die nationale Rechtslage zu den beiden Energiegemeinschaften dargestellt. Auf die Gemeinsamkeiten sowie Unterschiede wurde national noch genauer eingegangen. Die Analyse befasst sich mit den rechtlichen erforderlichen Schritten für die Gründung einer Energiegemeinschaft, wobei besonders Bedacht auf die Energieform, sowie Mitglieder, Reichweite, Erleichterungen und Förderungen genommen wurde. Der Analyse liegen die europäischen und nationalen Vorschriften zu Grunde unter Heranziehung der einschlägigen Literatur und Gesetzesmaterialien. Neben den allgemeinen Erfordernissen rund um die Energiegemeinschaft und jener in Bezug auf die Teilnehmer:innen, wurden auch Nutzungsmöglichkeiten und Notwendigkeiten für die Datennutzung aufgezeigt.

¹ Burgstaller/Holzleitner-Senck, Serve-U M8.2: Rechtsanalyse (2024)

Dieser Bericht D8.1 “Whitepaper: Empfehlungen für Anpassungen der regulatorischen Rahmenbedingungen” enthält Empfehlungen, die anhand der Rechtsanalyse und durch die Heranziehung von Stakeholdern ausgearbeitet werden konnten.

3.7.3 Energiegemeinschaften

Es gibt in Österreich zwei Arten von Energiegemeinschaften, einerseits die Bürgerenergiegemeinschaft und andererseits die Erneuerbare-Energie-Gemeinschaft. Beide Gemeinschaften haben eines gemeinsam, nämlich Energie über Grundstücksgrenzen hinaus gemeinschaftlich zu nutzen. Den Anstoß für die Einführung von Energiegemeinschaften hat die europäische Union durch zwei Richtlinien (Erneuerbare-Energie-Richtlinie (EU) 2018/2001² und Elektrizitätsbinnenmarkt-Richtlinie (EU) 2019/944)³) gegeben, welche nun seit Mitte letztes Jahr (2021) in Österreich durch unterschiedliche Vorgaben im Rahmen des Erneuerbaren-Ausbau-Gesetzespakets umgesetzt wurden. Nun können sich u.a. Personen, Unternehmen, Behörden und Gemeinden zusammenschließen und erneuerbare Energie (insbesondere Elektrizität) gemeinschaftlich nutzen.

3.7.4 White Paper: Empfehlungen

Die Grundlage für die nachfolgenden Empfehlungen basieren auf der Rechtsanalyse (siehe Anhang “Rechtsanalyse” M8.1⁴) und Interviews mit Stakeholdern, die drei unterschiedliche Projekte von Energiegemeinschaften begleiten. Alle drei Projekte haben gemeinsam, dass diese jeweils eine Erneuerbare-Energie-Gemeinschaft gründen. Diese gründen sich auf demselben Rechtsrahmen, aber haben eine unterschiedliche Zusammensetzung hinsichtlich Teilnehmer:innen, einbezogene Erzeugungsanlage(n) von Mitgliedern oder Erzeugern, Größe und Reichweite.⁵ Jede dieser Gemeinschaften hat positive Erfahrungen gesammelt, aber sie sehen auch in dem ein oder anderen Aspekt der Vorbereitung, Gründung und Betrieb einer Energiegemeinschaft Barrieren, die über ein Anpassungspotenzial verfügen. Gleiche und andere Hürden für EG konnten von Experten, Fachleute und politischen Entscheidungsträger in dem Workshop „Energiegemeinschaften in Österreich – Perspektiven der Weiterentwicklung“ (27.09.2022, FH Technikum Wien), welcher von den drei Forschungsprojekten DECIDE⁶, SENDER⁷, sowie Serve-U organisiert wurde, identifiziert werden.

Dieser Bericht zeigt Barrieren auf und gibt Handlungsempfehlungen ab, wo noch mehr Unterstützung für Energiegemeinschaften geboten werden könnte und wo Anpassungen des Rechtsrahmens empfehlenswert sind.

² Richtlinie (EU) 2018/2001 des Europäischen Parlaments und des Rates vom 11. Dezember 2018 zur Förderung der Nutzung von Energie aus erneuerbaren Quellen, ABl 2018 L 328/82 i.d.F. 2022 L 139/1.

³ Richtlinie (EU) 2019/944 des Europäischen Parlaments und des Rates vom 5. Juni 2019 mit gemeinsamen Vorschriften für den Elektrizitätsbinnenmarkt und zur Änderung der Richtlinie 2012/27/EU, ABl 2019 L 158/125 i.d.F. 2022 L 152/54.

⁴ Burgstaller/Holzleitner-Senck, Serve-U M8.2: Rechtsanalyse (2024)

⁵ Vgl. Burgstaller K./Becker/Frantes/Höhne, Energiegemeinschaften: Recht & erste Praxiserfahrungen, ZTR 2022, 145-153.

⁶ Webseite DECIDE, <https://decide4energy.eu/>.

⁷ Webseite SENDER, <https://www.sender-h2020.eu/>.

3.7.4.1 Betriebs- und Verfügungsgewalt

Eine Energiegemeinschaft kann nur dann funktionieren, wenn auch in der Gemeinschaft diese Energie erzeugt und verbraucht wird, was dem Sinn und Zweck des kollektiven Energieaustausches entspricht (sog. Energy Sharing). Daher ist eine wesentliche Frage bei der Gründung einer Energiegemeinschaft, ob eine Erzeugungsanlage von einem Mitglied eingebracht wird oder die Energiegemeinschaft selbst eine Erzeugungsanlage errichtet, kauft, pachtet und/oder ein zivilrechtliches Eigentum daran begründet soll.

Die europäische Grundlage für eine EEG und BEG geht davon aus, dass die Mitgliedstaaten sicherzustellen haben, dass die Gemeinschaft das Eigentum an deren Erzeugungsanlagen hält.⁸ Ausgehend von einem Eigentumsbegriff in der europäischen Grundlage wurde von Österreich ein Weg gewählt, welcher auch das Eigentum an einer Anlage umfasst und nicht ausschließt. Durch das Erfordernis der „Betriebs- und Verfügungsgewalt“ die von der EG über die Erzeugungsanlage gehalten werden muss wurde eine Möglichkeit geschaffen, nicht unbedingt Eigentümer:in einer Erzeugungsanlage sein zu müssen. Andere Formen der Eingliederung einer Erzeugungsanlage wurde damit geschaffen. Dennoch ist die Betriebs- und Verfügungsgewalt nicht einfach zu erfassen, sondern benötigt eigene vertragliche Einigungen mit dem Anlageneigentümer, der die Verfügungsgewalt an die Gemeinschaft überträgt. Dies wird dadurch entschärft, dass die Gemeinschaft nicht selbst den Betrieb über die Anlage übernehmen muss, sondern sich einem Dritten (ergo Dienstleister oder auch Anlageneigentümer als Verpächter) bedienen kann.⁹

Bei der Gründung einer Energiegemeinschaft ist nicht nur zu berücksichtigen, wie eine Erzeugungsanlage in die Gemeinschaft integriert werden kann, sondern auch wie der Betrieb organisiert wird. Entweder wird eine Erzeugungsanlage durch ihre Mitglieder selbst (wie eine PV-Anlage) eingebracht (zB als Überschussanlage oder Volleinspeiser)¹⁰ oder die Energiegemeinschaft organisiert eine eigene Erzeugungsanlage, indem eine Erzeugungsanlage durch die Energiegemeinschaft angeschafft wird oder eine Anlage im Rahmen eines Contracting-Vertrages gepachtet oder als Leasing-Modell erstanden wird.¹¹ Auch die Integration von Erzeugern, die ua größere Erzeugungsanlagen haben, wie Windpark, Wasserkraftanlagen etc. ist für eine EEG, nicht ausgeschlossen. Welche in der lex specialis in § 16c Abs. 1 EIWOG 2010 für bestimmte „souveräne“ Erzeuger festgelegt ist¹², sofern dieser in das Netz einspeist, dass im Nahebereich (Regional- oder Lokalbereich) einer EEG liegt.

Die Integration von Erzeugungsanlagen ist ua wie folgt möglich:

⁸ Vgl. Art 16 Abs. 3 lit e EBM-RL 2019 und Art 22 Abs. 2 lit b EE-RL 2018.

⁹ Vgl. § 16d Abs. 5 EIWOG 2010; siehe auch *Stangl*, Potenziale der Energiegemeinschaften , RdU-UT 2022/10 (46).

¹⁰ Vgl. auch *Koordinierungsstelle für Energiegemeinschaften*, Erneuerbare-Energie-Gemeinschaften für Anlagenbesitzer:innen – EEG Factsheet #3, 2022 (abrufbar unter: <https://energiegemeinschaften.gv.at/wp-content/uploads/sites/19/2022/06/EEG-Factsheet-fuer-AnlagenbesitzerInnen.pdf>).

¹¹ Vgl. auch *Stangl*, Potenziale der Energiegemeinschaften, RdU-UT 2022, 46; *Krönke/Tschachler*, Decentralized Energy , RdU 2021, 252 ff; ErläutRV 733 BlgNR 27. GP 26.

¹² Diese Erzeuger dürfen nicht von einem Versorger, Lieferanten oder Stromhändler iSd EIWOG 2010 kontrolliert werden.

- Als Überschusseinspeisung: Die Erzeugungsanlage bleibt im Eigentum des jeweiligen EG-Mitgliedes. Nur Strom im Ausmaß der Überschusseinspeisung wird der EEG/BEG zur Verfügung gestellt. Zivilrechtliche Vereinbarungen sind dafür zu schließen (wie Nutzungsvereinbarung, Vorrecht der zugeordneten Strommenge).
- Als gemietete oder gepachtete Anlage: Wo der Erzeugte Strom ausschließlich der EEG zur Verfügung steht.
- Als Volleinspeisung: Dabei wird der gesamte Strom der Energiegemeinschaft zur Verfügung gestellt.
- Als Eigenproduktion: Hierbei investiert und betreibt die Energiegemeinschaft eine Erzeugungsanlage, wobei die gesamte Produktion der Gemeinschaft zur Verfügung steht.¹³

In dem Zusammenhang ist festzuhalten, dass eine Erzeugungsanlage (sowie Verbrauchsanlage) ab 2024 an mehreren Energiegemeinschaften teilnehmen kann. Dadurch sind wohl weitere Vereinbarungen notwendig und auch die Bestimmung hinsichtlich „Betriebs- und Verfügungsgewalt“ muss dabei mitbedacht werden. Wodurch die Frage aufkommt, ob die Energiegemeinschaft ihren Überschussstrom oder Teile der Kapazitäten an andere Energiegemeinschaften verkauft oder die Betriebs- und Verfügungsgewalt geteilt werden kann (was derzeit schwer denkbar wäre, siehe nachfolgend).

Hinsichtlich der Erzeugungsanlagen ist für die BEG und EEG festgelegt, dass über die Erzeugungsanlage der Gemeinschaft, eben bei dieser die „Betriebs- und Verfügungsgewalt“ gem. § 16d Abs. 5 EIWOG 2010 zu liegen hat. Eine Definition dieser Befugnis ist weder im EIWOG 2010 oder EAG zu finden.¹⁴ Hinsichtlich der Betriebsgewalt eröffnet das Gesetz die Möglichkeit, dass ein Dritter mit dem Betrieb der Anlage beauftragt wird, wodurch Dienstleistungen ermöglicht werden, aber letzten Endes muss dennoch die Energiegemeinschaft die endgültige Verfügungsmacht oder Weisungsmacht eingeräumt werden. Ob das auch für jene souveränen Erzeuger als EEG-Mitglied¹⁵ nach der lex specials gilt ist fraglich. *Stangl* stellt die These auf, dass ein unabhängiger Erzeuger seine Rechtsposition verliert, wenn dieser die Betriebs- und Verfügungsgewalt auf die EEG übergibt, wodurch dieser selbst nicht mehr die Definition des Erzeugers erfüllt und damit seine Erzeugerstellung verliert. Die lex specials ist nicht nur auf größere Erzeugungsanlagen (wie nach ErlRV) sondern auch auf PV-Anlage am Dach anzuwenden, weil diese grundsätzlich nicht unter der Kontrolle von Versorger, Stromhändler oder Lieferanten liegen.¹⁶ Für andere Erzeuger der BEG gilt dies nicht.

Die Koordinierungsstelle für Energiegemeinschaften hat zwei unverbindliche Vertragsmuster erstellt, die von EG genutzt werden können. Einerseits handelt es sich um einen Vertrag, der eine Erzeugungsanlage als Überschusseinspeiser in die Gemeinschaft integriert und andererseits eine Anlage als Volleinspeiser

¹³ Vgl. Erneuerbare-Energie-Gemeinschaften: Steuern & Abgaben (abrufbar unter: [EEG_Ratgeber_Steuern_und_Abgaben.pdf](https://www.energiegemeinschaften.gv.at/EEG_Ratgeber_Steuern_und_Abgaben.pdf) ([energiegemeinschaften.gv.at](https://www.energiegemeinschaften.gv.at)))

¹⁴ Vgl. auch *Stangl*, Potenziale der Energiegemeinschaften, RdU-UT 2022, 46.

¹⁵ Arg. Die Bestimmung verweist auf die Bestimmung des EEG-Mitgliederkreises und ermöglicht nach dem Wortlaut des § 16c Abs. 1 die Teilnahme an einer EE, wodurch sie als Mitglied angesehen werden kann.

¹⁶ *Stangl*, Potenziale der Energiegemeinschaften, RdU-UT 2022, 47.

für die Energiegemeinschaft aufnimmt. Beide Vertragsvorlagen gehen davon aus, dass die Betriebs- und Verfügungsgewalt nicht streng sachenrechtliche Dimensionen annimmt, sondern durch vertragliche Konstruktionen die elektrizitätsrechtliche Bedingung erfüllt werden kann.¹⁷ An dieser Stelle ist festzuhalten, dass durch den unbestimmten Gesetzesbegriff der „Betriebs- und Verfügungsgewalt“ zwar eine gewisse Offenheit hinsichtlich der Integrierung von Erzeugungsanlagen besteht, dennoch fehlt es an einer gewissen Rechtssicherheit für die Energiegemeinschaften und den Anlageneigentümer:innen. Dies hängt ua damit zusammen, in wie weit die Erfüllung der Betriebs- und Verfügungsgewalt überprüft werden kann und Rechtssicherheit darüber gibt, ob die einzelne Gemeinschaft diese erfüllt hat (generell fehlt es an der Erwirkung eines Feststellungsbescheides über das Bestehen einer Energiegemeinschaft¹⁸). Es ist jedoch fraglich, ob der Netzbetreiber von dem genauen Inhalt des Vertrages Kenntnis haben muss (was gesetzlich nicht in § 16d Abs. 2 EIWOG 2010 festgelegt ist) bzw die Energiegemeinschaft dies verweigern kann. Zerteilt man „Betrieb“ und „Verfügung“ kann man davon ausgehen, dass jedenfalls der Betrieb der Erzeugungsanlage von der Energiegemeinschaft vertraglich geregelt werden muss, iSd § 16d Abs. 3 EIWOG 2010, aber es gibt keine Informationspflicht gegenüber den Netzbetreibern. Im Zusammenhang mit der Betriebs- und Verfügungsgewalt, die der Energiegemeinschaft zu übertragen ist, muss gemeinsam mit dem Zählpunkt der Erzeugungsanlage gesehen werden. Dabei ist festzuhalten, dass es nicht notwendig ist, dass die Eigentümer:in der Anlage auch der Erzeuger sein muss. Was gegeben sein muss ist, dass der Erzeuger jedenfalls die Betriebs- und Verfügungsgewalt über die Erzeugungsanlage hat. Nach derzeitiger Ansicht (*Hodasz, Stangl*, Rechtsprechung) ist es bei Überschusseinspeiseanlagen nicht möglich die Betriebs- und Verfügungsgewalt zu teilen. Dies gründet sich daraus, dass diese Anlagen grundsätzlich nur einen Zählpunkt haben. Rechtlich ist es nicht möglich einen Zählpunkt mit mehreren Personen zu teilen. Ein Erzeuger kann daher nur über seinen eigenen Zählpunkt in das Stromnetz einspeisen und darf dazu nicht den Zählpunkt eines Dritten, wie die des Mitgliedes der/die Erzeugungsanlage einbringt, nutzen.¹⁹ Um dieses Problem zu lösen wird einerseits diskutiert, ob es mit einer dynamischen Inbestandnahme²⁰ durch einen Vertrag über die Überschusseinspeisung erfolgen soll, was auch kritisch zu beurteilen ist. Weiters könnte es über die oben angesprochene Lösung sein, dass der teilnehmende Erzeuger weiterhin seine Erzeugerstellung behält (ohne Übergabe der Betriebs- und

¹⁷ Vgl. die Leitfaden zu Überschusseinspeiser (abrufbar unter: <https://energiegemeinschaften.gv.at/wp-content/uploads/sites/19/2022/09/Leitfaden-Ueberschusseinspeiser-V2-August-2022.pdf> [am 31.03.]) und Volleinspeiser (abrufbar unter: <https://energiegemeinschaften.gv.at/wp-content/uploads/sites/19/2022/09/Leitfaden-Volleinspeiser-V2-August-2022.pdf> [am 31.03.]), so auch

¹⁸ Vgl. dazu die Ausführungen von *Nigmatullin*, Bescheidmäßige Feststellung des Status "Energiegemeinschaft"? , *ecolex* 2022, 79 ff.

¹⁹ Vgl. *Hodasz*, §16d EAG, in Ennser (Hg), EAG (2022) Rz 8; *Stangl*, Potenziale der Energiegemeinschaften , RdU-UT 2022, 46-47, Entscheidung der Regulierungsbehörde vom 4. 3. 2020, GZ: R STR 05/19.

²⁰ Dies ist eine Vereinbarung hinsichtlich der Verfügungsgewalt über eine Erzeugungsanlage, die dynamisch ist und je nach Verhältnis von Eigenverbrauch und Überschusseinsparung erfolgt (siehe dazu mehr *Stangl*, Potenziale der Energiegemeinschaften, RdU-UT 2022, 46 ff).

Verfügungsgewalt) nur als Überschusseinspeiser in eine EEG integriert wird. Diese Möglichkeit würde nur für EEG und nicht für BEG bestehen.²¹

Neben den oben angeführten Barrieren, wurde im Gespräch mit den Stakeholdern Betriebs- und Verfügungsgewalt auch aus einer weiteren Perspektive betrachtet. Ausgangsbasis ist die Einbeziehung von großen Erzeugungsanlagen, die mehr als eine Energiegemeinschaft (insb. EEG) versorgen können bzw. bereits mehrere Endverbraucher (die eventuell gleichsam Eigentümer:innen sind) versorgen. Diese Anlagenbetreiber:innen möchten selbst einen Teil der Stromproduktion weiterhin an Kund:innen liefern, aber gleichzeitig auch die Gemeinschaft versorgen. Die Übertragung der Betriebs- und Verfügungsgewalt stellt hierfür eher eine Motivationsbremse hinsichtlich ihrer Beteiligung dar. Aus dem Blickwinkel der EG-Mitglieder können sich auch Bedenken ergeben. Eine Energiegemeinschaft hat zB kein Interesse daran über eine große Erzeugungsanlage zu verfügen, die im Eigentum einer anderen natürlichen oder juristischen Person steht. Ob die Möglichkeit der Mehrfachmitgliedschaft²² dieses Thema entschärfen wird ist fraglich, weil es an einer Definition der Betriebs- und Verfügungsgewalt fehlt bzw. auch Fragen eröffnet die zu klären sind. Auch hinsichtlich der oben angeführten Themen und Bedenken. Eine Klarstellung der Betriebs- und Verfügungsgewalt wäre empfehlenswert.

Aufgrund der aufgezeigten Komplexität der Thematik wird empfohlen, dass eine Klarstellung hinsichtlich der Betriebs- und Verfügungsgewalt vorgenommen wird. Hierbei sollte berücksichtigt werden, dass Besonderheiten für größere Erzeugungsanlagen bestehen können, wo einerseits die Energiegemeinschaft nur das absolut notwendige der Betriebs- und Verfügungsgewalt übernehmen möchte und andererseits, dass auch die Eigenschaften als Volleinspeiser oder als Übereinspeiser separat zu berücksichtigen sind.

3.7.4.2 Stromaufteilung in einer Gemeinschaft

Gesetzlich festgelegt ist, dass eine EEG und BEG ihren gemeinschaftlichen Strom entweder dynamisch oder statisch aufteilen kann.²³ Bei der statischen Aufteilung wird jedem Mitglied ein fixer Anteil am erzeugten Gemeinschaftsstrom zugesprochen, der zuvor vertraglich vereinbart wurde. Hierbei besteht die Gefahr, dass in einer Viertelstunde-Strom-Einheit produziert wird, die nicht ganz bzw. ineffizient von den Mitgliedern verbraucht werden kann, weil jedes Mitglied mit ihrem Anteil limitiert ist. Dabei kann ein Ungleichgewicht entstehen, weil Energie produziert wird, dass die nicht von allen Mitgliedern zu jedem Produktionszeitraum genutzt werden kann, oder diese Energie zwar von ein paar Mitglieder aufgebraucht werden könnte, aber diese durch den fixen Anteil je Viertelstunde begrenzt sind. Eine dynamische Aufteilung richtet sich nach dem Verbrauchsverhalten der Mitglieder. Wird in einer Viertelstunde Strom produziert, so erhält jenes Mitglied, das den höchsten Verbrauch hat, den größten Anteil an der erzeugten Energie. Dadurch können Diskrepanzen zwischen den Mitgliedern entstehen, weil Mitglieder mit höherem Verbrauch mehr profitieren, als jene die einen kleinen Verbrauch haben. Dabei ist auch der Zeitpunkt zwischen Produktion und Verbrauch zu beachten.

²¹ Vgl. *Stangl*, Potenziale der Energiegemeinschaften , RdU-UT 2022, 46-48.

²² Eine Teilnahme von Netznutzern mit ihren Erzeugungs- und/oder Verbrauchsanlagen an mehreren Energiegemeinschaften (EEG, BEG; oder § 16a-Anlage) ist erst ab 2024 möglich (vgl. § 111 Abs. 8 ElWOG 2010).

²³ § 16e Abs. 3 ElWOG 2010.

Mit der Gründung einer EEG oder BEG stellt sich die Frage, welcher Aufteilungsschlüssel auf die Mitgliederzusammensetzung am ehesten passend ist. Dafür ist zu analysieren wie das Verhältnis von Erzeugung und Verbrauch in der Gemeinschaft mit deren Mitgliedern sich darstellt, um den richtigen Verteilschlüssel festzulegen, der einen hohen Eigenverbrauch von eigenerzeugter Energie in der Gemeinschaft gewährleistet.²⁴ Gleichzeitig muss daran gedacht werden, dass Mitglieder zu einer Gemeinschaft hinzukommen und auch wieder austreten, wodurch der festgelegte Aufteilungsschlüssel eventuell nicht mehr passend ist. Es stellt sich die Frage, ob die zwei Möglichkeiten der Stromaufteilung ausreichend sind, um eine optimale Energienutzung in der Gemeinschaft zu erzielen.²⁵ Im Workshop wurde angemerkt, dass die Festlegung eines fixen Anteils der Mitglieder sich schwierig gestaltet, weil manche Netzbetreiber selbst den Aufteilungsschlüssel vorgeben/vorgeben wollen. Obwohl es gesetzlich nicht so vorgesehen ist, wird in der Praxis grundsätzlich nur die dynamische Aufteilung zugelassen. Auch die Gespräche mit den Stakeholdern haben gezeigt, dass die zwei Aufteilungsschlüssel nicht optimal sind. Je nach Konstellation der Energiegemeinschaft sind unterschiedliche Anforderungen zu erfüllen und es könnte ein Ungleichgewicht zwischen den Mitgliedern entstehen (Firma die tagsüber viel verbraucht, Familie die am Abend viel verbraucht oder am Tag je nach Lebensrhythmus). Eine unfaire Behandlung könnte hier entstehen, bzw. das Gefühl unter den Mitgliedern hervorrufen. Hinsichtlich einer bestmöglichen Energienutzung wurde angemerkt, dass die Aufteilungsschlüssel optimiert werden sollen. Hierfür könnte man einen Blick in andere EU-Länder riskieren, um andere Ansätze zu finden die auch für Österreich praktikabel sind. Es ist anzuregen, dass es mehrere Möglichkeiten geben sollte, wie Energie aufgeteilt werden kann.

Es wird empfohlen, dass die derzeit geltenden Aufteilungsschlüssel optimiert werden, um den effizienten Energie Austausch in Energiegemeinschaften weiter voranzutreiben. Hierbei könnten andere EU-Länder als Vergleich herangezogen werden.

3.7.4.3 Austausch von Informationen; Hilfreiche Werkzeuge

Die Koordinierungsstelle für Energiegemeinschaften ist die erste Anlaufstelle für Informationen rund um Energiegemeinschaften und die Gründung sowie Durchführung von Energiegemeinschaften. Zusammen mit den Beratungsstellen der Bundesländer werden Musterverträge, Leitfäden, Fragen und Antworten²⁶ aufbereitet, was ein wesentlicher Beitrag dafür ist, dass den Menschen ein Werkzeug an die Hand gegeben wird, selbst aktiv bei der Energiewende beizutragen. Auf der Webseite können sich

²⁴ Vgl. *Stangl*, Potenziale der Energiegemeinschaften, RdU-UT 2022, 45; Webseite Koordinierungsstelle Energiegemeinschaften, Benefit Tool - Erneuerbare Energiegemeinschaft (abrufbar unter: <https://energiegemeinschaften.gv.at/tools/>).

²⁵ Eine effiziente Nutzung der produzierten Energien der Gemeinschaft hängt auch mit der Marktprämie zusammen. Eine BEG und EEG können auch die Förderung durch eine Marktprämie erlangen, wobei sie auf 50 % der in der Gemeinschaft erzeugten Energie limitiert ist. Eine ineffiziente Nutzung der produzierten Energie, welche aus verschiedenen Gründen entstehen kann (Aufteilungsschlüssel, Mitgliederwechsel), beeinflusst auch daher den Zugang zu der Förderung durch die Marktprämie. Zu diesem Thema mehr nachfolgend in einem eigenen Kapitel.

²⁶ Abrufbar unter: <https://energiegemeinschaften.gv.at/faqs/>.

Energiegemeinschaften eintragen lassen und dabei sichtbar werden (Webauftritt), was aber nur für bestehende Gemeinschaften möglich ist. Auch Dienstleister sind auf der Webseite der Koordinierungsstelle vertreten.

In den Stakeholder-Gesprächen gab es weitere Ideen und Anregungen, wie interessierte Personen weiter unterstützt werden können, sich zu Energiegemeinschaften zusammenschließen. Es wurde darüber gesprochen einen Bereich zu bieten, wo sich Interessierte Personen vernetzen können. Interessierte Personen sollten unterstützt werden bei der Findung von passenden Verbraucher:innen und Erzeuger:innen in einer Region. Die Gemeindeebene bietet bereits eine gute Plattform, die Interessierte Personen zusammenführt – was von Stakeholdern positiv hervorgehoben wurde. Weiters wurde betont, dass ein gutes Netzwerk für Wissensaustausch und zum Probleme lösen sehr hilfreich ist, bei der Gründung einer Energiegemeinschaft. Gute und offene Kommunikationskanäle zu verschiedenen Akteuren, angefangen von den Netzbetreibern bis hin zur Koordinierungsstelle wurde als sehr positiv und notwendig erachtet. Neben den positiven Resonanzen wurde angesprochen, dass man motivierten Personen einen Raum bieten soll, wo sie sich mit anderen Interessierten für die Gründung einer Gemeinschaft zusammenfinden könnten. Der Erfahrungsaustausch zwischen bestehenden Energiegemeinschaften und interessierten Personen ist wesentlich. Dies könnte durch eine Kommunikationsplattform erfolgen, wo sich zB Bürger:innen und kleine Firmen austauschen können, welche Hürden wie überwunden werden konnten, wo es Erfahrungen gibt die an nächste Energiegemeinschaften weitergegeben werden können. Ein stetiger Ausbau der Webseite von der Koordinierungsstelle wäre von Vorteil.

Die Beratung der Koordinierungsstelle für Energiegemeinschaften bietet die Basisinformationen für die Gründung von Energiegemeinschaften. Empfohlen wird, dass sich die Webseite der Koordinierungsstelle weiterentwickelt und Raum bietet damit sich Interessierte Personen zusammenfinden können.

3.7.4.4 Allgemeine Anreize zur Eigenversorgung

Im Rahmen der Stakeholder Gespräche wurde festgestellt, dass die Motivation zur Umstellung von einer fossilen zu einer erneuerbaren Energieversorgung sich dahingehend unterscheidet, ob das Objekt ein Mietzinshaus ist oder an dem Objekt eine Eigentümergemeinschaft dahintersteht. Auch der Kommunikationsweg ist in einer Eigentümergemeinschaft einfacher zu organisieren als zwischen Eigentümer und deren Mieter:innen. Aufgrund dieser Erfahrung, wurde angeregt, dass nicht nur Eigentümer:innen, sondern auch Mieter:innen motiviert werden sollen den Eigenverbrauch im Haus zu optimieren und sich zB zu Energiegemeinschaften zusammenzuschließen. Dafür sollen auch Bauträger miteinbezogen werden, nachhaltige Lösungen bereits beim Bau einer Anlage mitzudenken, damit sich zB die Mieter:innen und Eigentümer:innen von benachbarten Gebäuden zu Energiegemeinschaften zusammenschließen können (durch zB nachträgliche Ermöglichung von PV-Anlagen am Dach). Vorgeschlagen wird daher Anreize zu setzen in Form von Informationen aber auch rechtlichen Verpflichtungen und Erleichterungen für erneuerbare Energie und sektorkoppelnde Lösungen. Dies könnte die Basis für gemeinschaftlichen Strom und die Optimierung des Eigenverbrauchs ebenen.

Teilnehmende an Energiegemeinschaften blicken in die Zukunft und sehen das Potenzial von gemeinschaftlicher Energienutzung, auch sektorübergreifend. Unterschiede sieht man zwischen Gebäudeeigentümer/Eigentümergemeinschaften und Mieter:innen. Es wird empfohlen, dass Anreize für Eigentümer:innen und auch Mieter:innen gesetzt werden. Zum einen hinsichtlich des

Zusammenschlusses zu Energiegemeinschaften (zB mit mehreren Nachbargebäuden, um ein gesamtheitliches Energiekonzept [Strom, Raumwärme, Warmwasser etc] umzusetzen) und zum anderen, dass bereits bei Planung und Bau von Gebäuden sektorkoppelnde, nachbarschaftliche Anlagen bzw. Anschlüsse vorbereitet bzw. ermöglicht werden.

3.7.4.5 Vereinfachung der Gründung einer Energiegemeinschaft

Wie in der Rechtsanalyse dargestellt, gibt es viele Schritte, die im Rahmen der Gründung durchgeführt werden müssen.²⁷ Neben der Gründung müssen einzelne Einwilligungen gegenüber dem Netzbetreiber für den Datenerhalt vorgelegt werden.²⁸ Im Rahmen des Projektes wurde darüber diskutiert, wie man die Fülle an Willenserklärungen, die von den interessierten Teilnehmer:innen benötigt werden, einfach und schnell für diese abgewickelt. Hier wurde als Vorschlag angeführt, dass eine Vollmacht für die Abgabe dieser Willenserklärungen benötigt wird. Daher sollte angedacht werden, dass Vollmachten für die Abgabe von Willenserklärungen im Rahmen der Gründung von Energiegemeinschaften gegenüber dem Netzbetreiber leichter anerkannt werden.

Es wird empfohlen, die Fülle an benötigten Willenserklärungen im Zusammenhang mit der Gründung durch Vollmachten gesetzlich zu berücksichtigen, um die Anerkennung bei dem Netzbetreiber zu erleichtern.

3.7.4.6 Förderinstrument Marktprämie

Im Rahmen der Stakeholder-Interviews wurde die Marktprämie für Energiegemeinschaften mit der Fördergrenze i.H.v. maximal 50 % der innerhalb einer EEG und BEG insgesamt erzeugten Strommenge thematisiert. An sich ist es zu begrüßen, dass beide Energiegemeinschaften in dem Fördersystem der Marktprämie berücksichtigt werden.²⁹ Zu Beginn des Gesetzgebungsprozesses war vorgesehen, dass beide Energiegemeinschaften durch Investitionszuschüsse gefördert werden können, wobei hinsichtlich der Marktprämie nur die EEG gefördert werden konnte und die BEG ausgeschlossen wurde. Mit dem Abänderungsantrag vom 7. Juli 2021 wurde vom Ausschluss der BEG abgesehen. Nun steht die Marktprämie auch für die BEG zur Verfügung. Die Prozent-Grenze wurde im Abänderungsantrag

²⁷ Vgl. insbesondere in der Rechtsanalyse Kapitel „Erneuerbare-Energie-Gemeinschaft im Vergleich zur Bürgerenergiegemeinschaft mit Fokus auf Elektrizität“, Unterkapitel „Gemeinsamkeiten bezüglich Gründung und vorrangiger Zweck von BEG und EEG“ und Kapitel „Elektrizitätsrechtliche Gemeinsamkeiten“.

²⁸ In der Rechtsanalyse im Kapitel „Conclusio“, Unterkapitel „Notwendige Schritte für den Datenerhalt und Zustimmung zur Datenverarbeitung“.

²⁹ Ein Unterschied zwischen der Regierungsvorlage zum EAG und dem tatsächlich beschlossenen EAG ist die Aufnahme von Energiegemeinschaften bei der Förderung von erneuerbarer Stromproduktion im Rahmen der Marktprämie. Energiegemeinschaften habe hierbei eine pauschale Begrenzung, da nur 50 % des innerhalb einer Energiegemeinschaft produzierten Strom durch Marktprämie gefördert werden kann.

dahingehend argumentiert, dass bei Energiegemeinschaften die gemeinsame Stromnutzung durch die Mitglieder im Vordergrund stehe und nicht eine Gewinnabsicht.³⁰

Die allgemeine Begrenzung könnte auch als Benachteiligung gesehen werden, da Energiegemeinschaften nur eingeschränkt am Fördersystem für Marktprämien teilhaben können im Gegensatz zu anderen Anlagenbetreibern. In der Literatur wurde die Verfassungsmäßigkeit dieser Norm diskutiert, da durch pauschale Förderbeschränkungen zahlreiche unions- und verfassungsrechtliche Spannungsfelder entstehen könnten.³¹ Aus der Praxis ergibt sich die Argumentation, dass die 50 % Grenze hinderlich sei, insbesondere auch im Zusammenhang mit der Thematik von größeren Erzeugungsanlagen, wie Windparks, Aufteilungsschlüsseln und möglicher wechselnder Mitglieder. Ein Anlagenbetreiber, der die Marktprämie außerhalb einer erneuerbaren Energiegemeinschaft erhält, hat keine Grenze hinsichtlich des erzeugten erneuerbaren Stroms. Dadurch wird die Erzeugung von Strom aus erneuerbaren Energien durch einen Anlagenbetreiber stärker gefördert als die gemeinschaftliche Erzeugung im Rahmen einer Energiegemeinschaft. Zu bedenken ist, dass die Marktprämie ein zeitlich begrenzter (ganz oder teilweise) Ausgleich zwischen den Produktionskosten von Strom aus erneuerbaren Quellen und dem durchschnittlichen Marktpreis für Strom schafft³², wodurch die Produktion von erneuerbarem Strom der Anreiz wird. Es ist daher an zu denken, dass die Förderung der Produktion von erneuerbarem Strom erweitert wird für EEG und BEG. Da auch sie einen Beitrag dafür leisten, das Energiesystem zu Dekarbonisierung.

Die allgemeine Begrenzung der Energiegemeinschaften hinsichtlich der Marktprämie sollte überdacht werden und den derzeitigen Gegebenheiten angepasst werden (unter Berücksichtigung der Thematiken wie Mitgliederwechsel und Aufteilungsschlüssel). Es wird empfohlen, dass im Fördersystem der Marktprämie das Potenzial von Energiegemeinschaften berücksichtigt und entsprechend in der Förderung aufgenommen wird.

3.7.4.7 Stabile Strompreise und Vergünstigungen

Thematisiert wurde die Strompreissituation aufgrund des Ukraine Krieges und die durchaus attraktiveren Verkaufspreise des erneuerbaren Stroms an die staatliche Förderstelle ÖMAG. Es wurden zwei Aspekte angesprochen, einerseits die finanzielle Attraktivität sich einer Energiegemeinschaft anzuschließen³³ und

³⁰ Vgl. dazu die Ministerialentwurf (58/ME 27. GP), Regierungsvorlage (ErläutRV 733 BlgNR 27. GP.) Und den Abänderungsantrag (AA-157 27. GP); mehr dazu in *Nigmatullin*, Unions- und verfassungsrechtliche Überlegungen zur Marktprämienförderung bei Energiegemeinschaften, RdU-UT 2021/17, 62 ff.

³¹ Vgl. mehr dazu in *Nigmatullin*, Unions- und verfassungsrechtliche Überlegungen zur Marktprämienförderung bei Energiegemeinschaften, RdU-UT 2021/17, 62 ff.

³² Vgl. §§ 9 bis 54 EAG.

³³ Laut E-Control gab es im Rahmen der Förderschiene „Marktpreis“ noch die Möglichkeit Strom von kleineren erneuerbaren Anlagen (>500 kW gem. § 13 iVm § 41 Abs 1 ÖSG 2012) bis 31.12.2022 zum Marktpreis an die OeMAG zu liefern. Viele Anlagenbetreiber hätten sich dazu entscheiden, ihren Strom vorerst an die OeMAG zu liefern, anstatt den Strom innerhalb einer Energiegemeinschaft zu teilen (vgl. dazu *E-Control*, Pressegespräch – Präsentation EAG- Monitoringbericht vom 10.10.2022, 10 (verfügbar unter: https://www.e-control.at/aktuelle-pressemeldungen/-/asset_publisher/QxlzOPQwGYnK/content/pressegespr%25C3%25A4ch-pr%25C3%25A4sentation-eag-monitoringbericht-);

andererseits beständige Mitgliedschaften von Erzeugungsanlagen zu haben (sofern die Energiegemeinschaft selbst keine Eigentümer:in oder Pächter:in eigener Erzeugungsanlage ist). Einige Energiegemeinschaften haben sich wohl schon mit diesen Aspekten beschäftigen müssen, wie auch die der einbezogenen Stakeholder. Hierbei ist hervorzuheben, dass mehrere Regelungen eine Rolle spielen die beachtet werden müssen, wie die „freiwillig und offen“³⁴ Teilnahme an Energiegemeinschaften (welches auch den Austritt mit umfasst³⁵) sowie auch i.Z.m. der Einbindung der Erzeugungsanlagen von Mitglieder:innen (Überschusseinspeiser) zu berücksichtigen sind. Insbesondere ist auch die Betriebs- und Verfügungsgewalt über Erzeugungsanlagen genau zu betrachten und vertraglich zu regeln. Wie der Preis für Energie in der Gemeinschaft oder auch die Einnahmen vom Verkauf von Überschüssen können unter den Teilnehmer:innen frei vereinbart werden.³⁶ Dies ist sehr positiv zu werten und macht die Teilnahme an einer Energiegemeinschaft wieder attraktiver (trotz der Strompreisentwicklungen seit Februar 2022). Unter der erschwerten Situation, die sich Energiegemeinschaften stellen mussten hat die zunehmende Zahl an tätigen Energiegemeinschaften auf der EDA-Plattform³⁷ und den EAG- Monitoringbericht (2022 und 2023)³⁸ der E-Control gezeigt, dass es motivierte Personen und Firmen gibt, die unabhängiger vom Energiemarkt sein möchten und selbst die Produktion von Energie in die Hand nehmen. Um den oben angesprochenen Problematiken entgegenzuwirken, wird empfohlen, dass die Thematiken hinsichtlich des Mitgliederwechsels, die Betriebs- und Verfügungsgewalt über Erzeugungsanlagen, sowie Förderungen für die Produktion erneuerbaren Stroms, auch für die Mitgliedschaft innerhalb von Energiegemeinschaften zu attraktivieren sind, durch Weiterentwicklung des Rechtsrahmens und setzen von Anreizen.

Der Strompreis beeinflusst so manchen Anlagenbetreiber (wie ein klassisches Mitglied einer Energiegemeinschaft, der Überschusseinspeiser) bei der Entscheidung sich einer Energiegemeinschaft anzuschließen, oder aus einer Gemeinschaft auszutreten. Es wird empfohlen, die Attraktivität sich einer Energiegemeinschaft anzuschließen und primär dort Energie zu verkaufen, zu steigern. Damit zusammenhängend sind die aufgezeigten Problematiken, wie die Betriebs- und Verfügungsgewalt, Mitgliederwechsel und Förderungen zu beseitigen, da dies einen Einfluss auf die Entscheidung der Vermarktung von eigens erzeugtem Strom hat, neben dem Strompreis.

3.7.4.8 Datenfluss und Datenerhalt

Im Laufe des Projektes und die Implementierung der App von Serve-U hat sich herausgestellt, dass die Datenübermittlung von den Netzbetreibern (über die EDA-Plattform) nicht immer zeitgerecht erfolgt. Grundsätzlich sollte es möglich sein, ab der Auslesung des Zählpunktes dessen Daten innerhalb des nächsten Tages (Folgetages) zu erhalten. Bei vielen Netzbetreibern werden die Daten in einem

vgl. iZm diesem Themenbereich auch den Artikel *Cejka*, Energiekosten steigen, Energieabgaben sinken (temporär) - Auswirkungen auf Energiegemeinschaften?, RdU 2022/89, 181ff.

³⁴ § 79 Abs. 2 letzter Satz EAG; § 16b Abs. 2 letzter Satz ElWOG 2010.

³⁵ Vgl. *Cejka*, Energiegemeinschaften im Clean Energy Package der EU, *ecolox* 2020, 338 (339).

³⁶ Vgl. hierzu auch die Informationen von der Website EDA, abzurufen unter: <https://www.eda.at/energiegemeinschaften>.

³⁷ Vgl. die Webseite der EDA-Plattform, abrufbar unter: <https://www.eda.at/fakten>.

³⁸ Abrufbar sind die Berichte auf der E-Control Webseite unter: <https://www.e-control.at/eag-monitoringbericht>.

angemessenen Zeitrahmen übermittelt, jedoch gibt es Ausnahmen, wo die Datenübermittlung zeitverzögert erfolgt. Um in Österreich, ohne zusätzliche Installationen und in angemessener Zeit, Stromdaten zu erhalten, ist es empfehlenswert das Angebot von ebUtilities (insb. EDA-Plattform) zu nutzen.

Der Energiedatenaustausch ist möglich, jedoch wird empfohlen, dass rechtlich und technisch angestrebt werden sollte, eine Auslesung der Smart Meter mehrmals pro Tag zu ermöglichen und dass diese Daten auch dementsprechend an die berechtigten Parteien (wie Dienstleister) weitergeleitet werden. Dadurch kann eine intensivere Unterstützung der Endverbraucher:innen bei einer energieeffizienten gemeinschaftlichen Energienutzung geboten werden.

3.7.4.9 Zusammenfassung der Empfehlungen von D8.1 “Withepaper: Empfehlungen für Anpassungen der regulatorischen Rahmenbedingungen”

Durchgehend ist erkennbar, dass sich verschiedene Aspekte von Energiegemeinschaften ergänzen, aber auch Schwierigkeiten mit sich bringen. Die Empfehlungen gehen Hand in Hand. Verschiedene Aspekte der Energiegemeinschaftsregelungen sollten klargestellt und weiterentwickelt werden, da die Problematiken zusammenhängen. Dies hängt unter anderem zusammen mit Mitgliederkreis, Mitgliederwechsel (Verbraucher:innen und Erzeuger), Größe der Erzeugungsanlagen sowie Förderungen bei der Vermarktung (Strompreis, Marktprämie).

Die Empfehlungen beziehen sich auf die Klarstellung und Vereinfachung der Betriebs- und Verfügungsgewalt, häufigerer und kontinuierlicherer Datenfluss, Schaffung mehrerer Möglichkeiten für die Verteilung des Stroms (Aufteilungsschlüssel), Anreize für den Zusammenschluss zu Energiegemeinschaften für Gebäudeeigen-/miteigentümer und Mieter:innen, Unterstützung bei zusammenfinden von interessierten Personen, sowie bei Förderungen und Anreizsetzung die Mitglieder von Energiegemeinschaften stärker einbeziehen.

3.7.5 Ergebnisse soziotechnologischer Begleitforschung und Umfragen

Die Ergebnisse der begleitenden sozio-technologischen Forschung und der durchgeführten Befragungen werden im Deliverable 8.2 ausführlich beschrieben. Eine Übersicht der Ergebnisse finden Sie hier.

Aufgrund der Ergebnisse der Befragungen, kann man davon ausgehen, dass Potential und Motivation zur Lastverschiebung vorhanden ist. Die Befragungen haben außerdem gezeigt, dass sich viele Testpersonen von der App motiviert fühlten und gleichzeitig keine zusätzlichen Maßnahmen zum Stromsparen getroffen haben. Bezüglich der konkreten Durchführung von Lastverschiebungen besteht weiterer Forschungsbedarf, da sich gezeigt hat, dass die Nutzung der App oft nicht mit der Zuständigkeit des Bedienens der Haushaltsgeräte übereinstimmt.

4 Ausblick und Empfehlungen

Die gewonnenen Erkenntnisse aus dem Projekt serve-U leisten einen wertvollen Beitrag für die Errichtung von Prosumer Plattformen für erneuerbare Energien und liefern der Forschung wertvolle empirische Daten für weitere Tätigkeiten in den Bereichen Energieoptimierung und Nutzerverhalten. Die Konzipierung der Serve-U Plattform ist darauf ausgerichtet Erneuerbare-Energie-Gemeinschaften (EEG) aber auch Bürgerenergiegemeinschaften (BEG) zu unterstützen, deren Effizienz, Eigenverbrauchsgrad und

Autarkiegrad zu steigern. Dies geschieht im Einklang mit den erklärten Zielen der österreichischen Bundesregierung, da die EEG ihren Mitgliedern wirtschaftliche, ökologische und sozialgemeinschaftliche Vorteile bringen soll [19]. Im Hinblick auf das Eine-Million-Dächer-Programm, das einen Zubau von 11 GW Photovoltaik bis 2030 vorsieht [20], sowie die steigenden Zahlen von Energiegemeinschaften wird das enorme Zukunftspotential von Serve-U bei einer Steigerung des Eigenverbrauchs innerhalb von EEGs zwischen 10 % bis theoretisch 30 % in den betrachteten Fällen.

Es gehört zu den größten Herausforderungen zukünftiger Energiesysteme, dieses Potenzial weiter zu erforschen, um die Aufnahme erneuerbarer Energiequellen weiter zu erhöhen. Wie in Serve-U erwartet und verifiziert wurde, hängt die Effektivität jeder Form der kurzfristigen Flexibilitätsoptimierung stark von der Genauigkeit der Prognosetechnologien ab, einschließlich der Prognose des Stromverbrauchs (flexibel oder nicht flexibel). Angesichts der stochastischen Natur des Verhaltens von Menschen und der Wetterbedingungen ist die Prognose des Stromverbrauchs noch weit davon entfernt, gut verstanden und modelliert zu sein. Die Analyse und Bewertung von Serve-U hat gezeigt, dass selbst kürzlich entwickelte und leistungsstarke KI-Modelle möglicherweise nicht die Genauigkeit und Robustheit der Vorhersagen gegenüber einfachen Modellen, wie Standard-Persistenzmodellen oder Kombinationen von Persistenz- und autoregressiven Modellen, verbessern können. Der Grund dafür könnte darin liegen, dass die Leistung stark von der Fähigkeit des Modells abhängt, zeitliche Muster im Verhalten der Nutzer und deren Dynamik zu erfassen, anstatt durchschnittliches Verhalten zu erfassen. Aus diesem Grund sollte die zukünftige Modellentwicklung für die Prognose des Stromverbrauchs besser Domänenwissen in das Design von Vorhersagemodellen integrieren, die das Verhalten der Nutzer besser erfassen können.

In den Funktionsvalidierungsphasen konnte gezeigt werden, dass trotz der Komplexität der Prognosen und der Unschärfe durch die getätigten Annahmen in der Optimierung deutliche Potentiale zu erkennen waren. Diese ersten positiven Ergebnisse sind jedoch nicht ausreichend, um generelle Aussagen über die Effektivität des dargelegten Konzeptes zu machen. Dafür sind deutlich größer angelegte Studien sowohl auf die Anzahl der Teilnehmenden als auch den zeitlichen Verlauf nötig. Das entwickelte Optimierungsmodell ermöglicht schnelle Lastverschiebungsmeldungen bei gleichzeitiger Nachvollziehbarkeit der Entscheidungen und erfüllt die Anforderungen der Anwendung daher vollkommen. Eine der größten identifizierten Schwierigkeiten ist es die Motivation der Teilnehmenden hochzuhalten. Zur anhaltenden Aktivität der Nutzenden bedarf es einer sehr durchdachten Applikation (Stichwort User Experience), welche neben einem sehr ansprechenden Grafik-Design sowohl allgemein verständliche als auch nachvollziehbare Lastverschiebungs-Aktionen bereitstellt. Des Weiteren müsste intensives Nudging betrieben werden, um eine kontinuierlich hohe Nutzung des Service zu gewährleisten.

Die Erhöhung des Eigenverbrauchs und die Reduktion von Erzeugungsspitzen ist durch Serve-U zwar realisierbar, jedoch bedarf es zu einem echten Beitrag zur Netzdienlichkeit einer garantierten Funktion der Mechanismen. Diese können zwar von Energiegemeinschaften umgesetzt oder mitgetragen werden, bedürfen aber einer größeren Betrachtung des Energienetzes. Aus diesen Gründen ist das untersuchte Konzept in dieser Form nicht für eine echte Entlastung des Elektrizitätsnetzes geeignet.

Ein entscheidender Aspekt für das hohe ökonomische Zukunftspotential der Serve-U Plattform liegt in der hohen Skalierbarkeit des Systems. Auch wenn bei einer Kommerzialisierung des Dienstes laufende Betriebskosten, sowie Kosten für die Weiterentwicklung anfallen, kann die Plattform von positiven Skaleneffekten profitieren und führt bei steigender Nutzerzahl zu einer Fixkostendegression. Darüber hinaus würde das Serve-U Geschäftsmodell bei steigender Anzahl der Nutzer:innen neben den

Skaleneffekten auch eine Qualitätssteigerung bedeuten. Das geschieht zum Teil vollautomatisch, da selbstlernende Verbrauchsprognosen bessere Resultate erzielen können, wenn eine große Anzahl der Nutzer:innen Daten bereitstellen, welche zur Fortentwicklung des Dienstes benötigt werden. Darüber hinaus bietet die technologieübergreifende Plattformgestaltung und das hohe Skalierungspotential zusätzliche Anwendungsfelder, die sich nicht auf den Einsatz in EG beschränken.

Das im Serve-U Konzept enthaltene wirtschaftlich/ ökologische Potential eignet sich hervorragend für die Lizenzierung an Drittanbieter. Diese könnten Serve-U als Produktbaustein in das eigene Produkt implementieren. Die Open-Source Charakteristik der Service Plattform wird eine Weiterentwicklung durch relevante Stakeholder bewusst erleichtert. Aufgrund des Low-Cost-Optimierungsansatzes und der aktiven Einbindung der Nutzer:innen dient Serve-U nicht nur als Enabler für die großflächige Ausrollung von EG, sondern bietet auch anderen Stakeholdern ökonomisch relevante Vorteile. Zum Beispiel könnten die gebündelten Prognosedaten bei einer großen Anzahl von EG den Netzbetreiber:innen wertvolle Informationen über die zu erwartenden Energiemenge liefern.

Während die Nutzer:innen bei der Funktionsvalidierung des Serve-U Konzepts nach dem Senden automatisierter Handlungsempfehlungen für Lastverschiebungen noch selbst verantwortlich sind diese Lasten ein- bzw. auszuschalten, kann man davon ausgehen, dass dies in Zukunft vollautomatisch geschieht. Die Vernetzung von Verbrauchern in Gebäuden, oder gar von ganzen Siedlungen oder Städten, birgt für das Serve-U Konzept durch seine technologieübergreifende Plattformgestaltung ein enormes Zukunftspotential. Verfügen z.B. Smart-Homes über eine sowohl eigene Anlage für die Gewinnung von EE, als auch über genormte Schnittstellen zur Kommunikation mit für Lastverschiebungen in Frage kommenden Verbrauchern, wäre Serve-U der ideale Dienst, um den Autarkiegrad dieser Gebäude zusätzlich zu verbessern.

Um derartige Funktionsmodelle einer breiten Bevölkerung zugänglich machen zu können, sollten möglichst eine diverse Zielgruppe an Co-Entwicklungs-Prozessen teilnehmen können. Daher benötigt es weitere Forschung, um Wege zu finden, wie eine diverse Zielgruppe erreicht werden kann. Wie könnte eine Kommunikations- und Engagement-Strategie aussehen, um Personen zu interessieren und aktivieren. Dazu sollte z.B. bekannt sein, was der Stand des Wissens ist und welche Motivatoren angesprochen werden können.

Im **D8.1 “Withepaper: Empfehlungen für Anpassungen der regulatorischen Rahmenbedingungen”** wurden die Empfehlungen in Form eines With Papers dargelegt. Die Empfehlungen reichen von der gesetzlichen Ausgestaltung der Möglichkeiten bis hin zu Förderungen und Datenerhalt. Die Empfehlungen umfassen acht Themenbereiche, die sich teilweise gegenseitig bedingen. Die **Empfehlungen** werden im Folgenden kurz zusammengefasst dargestellt:

- **Klarstellung der Betriebs- und Verfügungsgewalt:** Berücksichtigung von Besonderheiten für große Erzeugungsanlagen und die Unterscheidung zwischen Volleinspeisern und Übereinspeisern.
- **Optimierung der Aufteilungsschlüssel:** Nutzung von Best Practices aus anderen EU-Ländern zur Förderung effizienten Energieaustauschs.
- **Weiterentwicklung der Koordinierungsstellen-Website:** Schaffung eines Raums für Interessierte, um sich zu vernetzen und zu informieren.
- **Anreize für Gebäudeeigentümer und Mieter:innen:** Förderung von Zusammenschlüssen zu Energiegemeinschaften und sektorkoppelnden Energiekonzepten.

- **Berücksichtigung von Vollmachten zur Gründung:** Erleichterung der Anerkennung durch Netzbetreiber.
- **Überprüfung der Marktprämienbegrenzung:** Anpassung an aktuelle Gegebenheiten und Berücksichtigung des Potenzials von Energiegemeinschaften in Förderprogrammen.
- **Steigerung der Attraktivität durch Strompreis und Vermarktung:** Beseitigung von Problemen wie Betriebs- und Verfügungsgewalt, Mitgliederwechsel und Förderungen, um die Entscheidung für den Anschluss an eine Energiegemeinschaft zu erleichtern.
- **Intensivierung des Energiedatenaustauschs:** Ziel einer mehrmaligen täglichen Auslesung der Smart Meter und Weiterleitung relevanter Daten an berechnigte Parteien zur Unterstützung bei energieeffizienter Nutzung.

Die Empfehlungen aus rechtlicher Perspektive lassen sich wie folgt zusammenfassen: Die verschiedenen Aspekte von Energiegemeinschaften ergänzen sich, bringen aber auch Herausforderungen mit sich, die in wechselseitiger Synergie angegangen werden müssen, wie den Mitgliederkreis, den Mitgliederwechsel, die Erzeugungsanlagengröße und Förderungen bei der Vermarktung. Die Empfehlungen umfassen unter anderem die Klarstellung und Vereinfachung der Betriebs- und Verfügungsgewalt, die Förderung eines häufigeren und kontinuierlicheren Datenflusses sowie die Schaffung verschiedener Möglichkeiten für die Stromverteilung. Zusätzlich werden Anreize für den Zusammenschluss zu Energiegemeinschaften, Unterstützung beim Finden interessierter Personen und eine verstärkte Einbindung der Mitglieder bei Förderungen und Anreizen empfohlen.

5 Literaturverzeichnis

- [1] L. Ljung, *System identification: theory for the user*, 2. ed., 14. printing. in Prentice-Hall information and system sciences series. Upper Saddle River, NJ: Prentice Hall, 1999.
- [2] M. Szmit, S. Adamus, S. Bugała, and A. Szmit, 'Implementation of Brutlag's algorithm in Anomaly Detection 3.0', p. 7, 2012.
- [3] A. V. Kychkin and G. C. Chasparis, 'Feature and model selection for day-ahead electricity-load forecasting in residential buildings', *Energy and Buildings*, vol. 249, p. 111200, Oct. 2021, doi: 10.1016/j.enbuild.2021.111200.
- [4] A. Kychkin and G. C. Chasparis, 'AI-Powered Predictions for Electricity Load in Prosumer Communities', Feb. 21, 2024, *arXiv*: arXiv:2402.13752. Accessed: Feb. 26, 2024. [Online]. Available: <http://arxiv.org/abs/2402.13752>
- [5] K. G. Sheela and S. N. Deepa, 'Review on Methods to Fix Number of Hidden Neurons in Neural Networks', *Mathematical Problems in Engineering*, vol. 2013, no. 1, p. 425740, 2013, doi: 10.1155/2013/425740.
- [6] 'Using Prophet Algorithm for Pattern Recognition and Short Term Forecasting of Load Demand Based on Seasonality and Exogenous Features', ResearchGate. Accessed: Jan. 23, 2025. [Online]. Available: https://www.researchgate.net/publication/352578411_Using_Prophet_Algorithm_for_Pattern_Recognition_and_Short_Term_Forecasting_of_Load_Demand_Based_on_Seasonality_and_Exogenous_Features
- [7] S. F. Stefenon, L. O. Seman, V. C. Mariani, and L. dos S. Coelho, 'Aggregating Prophet and Seasonal Trend Decomposition for Time Series Forecasting of Italian Electricity Spot Prices', *Energies*, vol. 16, no. 3, Art. no. 3, Jan. 2023, doi: 10.3390/en16031371.

- [8] S. Hochreiter and J. Schmidhuber, 'Long Short-Term Memory', *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [9] N. Cesa-Bianchi and G. Lugosi, *Prediction, Learning, and Games*, 1st ed. Cambridge University Press, 2006. doi: 10.1017/CBO9780511546921.
- [10] T. Grubinger, G. C. Chasparis, and T. Natschläger, 'Generalized online transfer learning for climate control in residential buildings', *Energy and Buildings*, vol. 139, pp. 63–71, Mar. 2017, doi: 10.1016/j.enbuild.2016.12.074.
- [11] G. Chasparis, S. Luftensteiner, and M. Mayr, 'Generalized Input-Output Hidden-Markov-Models for Supervising Industrial Processes', *Procedia Computer Science*, vol. 200, pp. 1402–1411, Jan. 2022, doi: 10.1016/j.procs.2022.01.341.
- [12] S. Sharda, M. Singh, and K. Sharma, 'Demand side management through load shifting in IoT based HEMS: Overview, challenges and opportunities', *Sustainable Cities and Society*, vol. 65, p. 102517, Feb. 2021, doi: 10.1016/j.scs.2020.102517.
- [13] 'ZTR 2022, 145: Energiegemeinschaften: Recht & erste Praxiserfahrungen (Katrin Burgstaller / Gernot Becker / Bettina Frantes / Ulfert Höhne): RDB Rechtsdatenbank'. Accessed: Jan. 23, 2025. [Online]. Available: <https://rdb.manz.at/document/rdb.tso.LIztr20220301>
- [14] Switchboard, 'Willkommen | API Marktplatz für Energieservices'. Accessed: Mar. 01, 2022. [Online]. Available: <https://www.switchboard-api.de/>
- [15] Venios, 'Venios® Vereinigt IT und Energie', Venios® Vereinigt IT und Energie. Accessed: Mar. 01, 2022. [Online]. Available: <https://venios.de/en/>
- [16] A. SMA Solar Technology, 'SMA Solar Technology AG - Inverter & Photovoltaics solutions'. Accessed: Mar. 01, 2022. [Online]. Available: <https://www.sma.de/en.html>
- [17] Smappee, 'Smartes Energiemanagement', Smappee. Accessed: Mar. 07, 2022. [Online]. Available: <https://www.smappee.com/de/infinity/>
- [18] L. Gaisberger, G. Chasparis, and W. Traunmüller, 'Load Shifting in Energy Communities by Providing User-Centered Recommendations – Forecast, Optimization and Potential', *41st European Photovoltaic Solar Energy Conference and Exhibition*, pp. 020519-001-020519-006, 2024, doi: 10.4229/EUPVSEC2024/5DV.2.17.
- [19] Klima- und Energiefonds, 'Struktur - Energiegemeinschaften'. Accessed: Feb. 28, 2022. [Online]. Available: <https://energiegemeinschaften.gv.at/struktur/>
- [20] BMK, 'Mit Sonnenstrom zur Energiewende: Das Eine-Million-Dächer-Programm'. Accessed: Feb. 28, 2022. [Online]. Available: https://www.bmk.gv.at/service/presse/gewessler/20200910_sonnenstrom.html

6 Anhang

Deliverables

7 Kontaktdaten

Michael Schmidthaler
FH Oberösterreich
Wehrgrabengasse 1-3 | 4400 Steyr/Austria
Tel.: +43 50 804 33481 | Fax: +43 50 804 33599
M.: 0664 804 8433481
Michael.Schmidthaler@fh-steyr.at
<https://fh-ooe.at/>
<https://serve-u.at/>

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

SCCH – Software Competence Center Hagenberg

Energieinstitut an der JKU Linz

FH Technikum Wien

Blue Sky

OurPower

ATB Becker

Tobias Mühlberger

Sonnenplatz Großschönau

Innsbrucker Kommunalbetriebe