

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

Abschlussbericht

EVEKT

– Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien und datenbasierte Mehrwertdienste

Teilprojekt:

Energiemonitoring privater Haushalte zur Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien

Zuwendungsempfänger: Technische Hochschule Nürnberg Georg Simon Ohm

Förderkennzeichen: 03EI5234A

Laufzeit des Vorhabens: 01.07.2022 – 31.08.2025

Berichtszeitraum: 01.07.2022 – 31.08.2025

Erstellt von:

M.Sc. Kyriaki Koutrouveli, M.Eng. Christiane Dettelbacher, M.Eng. Omar Elattar,
Prof. Dr. Ivana Mladenovic

31. August 2025

Inhaltsverzeichnis

Abbildungsverzeichnis.....	3
Tabellenverzeichnis	4
1 Allgemeine Projektangaben	6
1.1 Kurzbeschreibung und Voraussetzungen des Vorhabens.....	6
1.2 Ausgangssituation und Stand der Technik zum Vorhabenbeginn 07/2022.....	8
1.3 Planung und Ablauf des Vorhabens.....	13
1.4 Zusammenarbeit mit anderen Stellen.....	16
2 Darstellung der Projektdurchführung.....	17
2.1 Ergebnisse des Projektes	17
AP 1 Vorbereiten der sozialwissenschaftlichen Begleitforschung.....	17
AP 3 Entwicklung KI-basierter Algorithmen.....	21
AP 4 Rechtliche Bewertung des Designs, Definition von Anpassungen und Umsetzung	30
AP 5 Erprobung der entwickelten Technologien/Algorithmen in der Pilotanwendung Herzo Base sowie Chancen, Risiken und Profiteure der entwickelten Technologien.	31
2.2 Verwendung der Zuwendung	58
2.3 Verwertungsplan	58
2.4 Stand der Technik während der Projektlaufzeit	58
3 Zusammenfassung	61
4 Veröffentlichungen, Poster und Vorträge.....	62
5 Anhang.....	62
6 Literatur	63
7 Danksagung	66

Abbildungsverzeichnis

Abbildung 1 Jahresstrommix des gesamten Gebäudes in Herzo Base von 2019 bis 2022	20
Abbildung 2: Aufgestellter Server im Rack in der Technikzentrale des Gebäudes	22
Abbildung 3: Berechnete mittlere Tagesgrundlast (orange) und mittlerer Tagesverbrauch (blau) während der Urlaubszeiten	25
Abbildung 4: Disaggregationsergebnisse für die Kühl- und Gefriergeräte in den Haushalten	26
Abbildung 5: Disaggregationsergebnisse für die kurzzeitig intensiven Stromverbraucher in H1, H2 und H3 Haushalten	27
Abbildung 6: Disaggregationsergebnisse für den gesamten Verbrauch der kumulierten intensiven Stromverbraucher in H1, H2 und H3	28
Abbildung 7: Tatsächliche PV- Erzeugung im Vergleich zu der prognostizierten Erzeugung von drei Solarprognose Tools	30
Abbildung 8: Technisches Setup der Mess- und Kommunikationsinfrastruktur in einem Quartier	32
Abbildung 9: Zustimmung zum Zugriff auf Energieverbrauchsdaten; Anmerkung: in Prozent	56

Tabellenverzeichnis

Tabelle 1: Studien zum Energieeinsparpotenzial durch digitale Energiesparanwendungen	8
Tabelle 2: Pflichteinbaufälle i.S.d. § 29 i.V.m. 31, 32 MsbG (für das Jahr 2021) [26].....	11
Tabelle 3: Optionaler Einbau i.S.d. § 29 i.V.m. 31 MsbG (für das Jahr 2021) [26].....	12
Tabelle 4: Kosten für den Betrieb von Smart Metern in Abhängigkeit vom jährlichen Stromverbrauch (Stand 2022) [27].....	12
Tabelle 5: Kosten für den Betrieb von Smart Metern bei dem Vorhandensein bestimmter Anlagen (Stand 2022) [27].....	13
Tabelle 6: Treibgasemissionen der verschiedenen Energiequellen des verbrauchten Stroms in Herzo Base [16][21]	20
Tabelle 7: CO ₂ e-Emissionen pro Haushalt in Tonnen zwischen 2019 und 2022.....	21
Tabelle 8: Verteilung der Messsteckdosen in den ausgewählten Haushalten	22
Tabelle 9: E _{Acc} and M _R (8-Stunden Fenster) (E _{Acc} /M _R) für die Kühl- und Gefriergeräte in den drei Haushalten. KS: Kühlschrank, GT: Gefriertruhe.....	25
Tabelle 10: E _{Acc} und M _R Werte (8-Stunden Fenster) für die kurzzeitig intensiven Stromverbraucher in den Haushalten H1, H2 und H3, WM: Waschmaschine, GS: Geschirrspüler und WT: Wäschetrockner	26
Tabelle 11: E _{Acc} und M _R Werte (8-Stunden Fenster) für die kumulierten intensiven Stromverbraucher in H1, H2 und H3.....	27
Tabelle 12: Jahresverbrauch in kWh/a der teilnehmenden Haushalte in Herzo Base für 6 Jahren	33
Tabelle 13: Mögliche Stromeinsparungen der teilnehmenden Haushalte in Herzo Base [kWh/a]	34
Tabelle 14: Mögliche Kosteneinsparungen der teilnehmenden Haushalte in Herzo Base [Euro/a]	34
Tabelle 15: Mögliche CO ₂ e-Einsparungen der teilnehmenden Haushalte für vier Einsparszenarien [kgCO ₂ e/a]	34
Tabelle 16: Mögliche CO ₂ e-Einsparungen der teilnehmenden Haushalte in Herzo Base anhand des deutschen Strommixes für vier Einsparszenarien [kgCO ₂ e/a]	35

Tabelle 17: Mögliche Stromeinsparungen in einem durchschnittlichen deutschen Haushalt für die vier Einsparszenarien [kWh/a]	35
Tabelle 18: Mögliche Kosteneinsparungen für einen durchschnittlichen deutschen Haushalt für die vier Einsparszenarien [Euro/a]	36
Tabelle 19: Amortisationszeit für einen durchschnittlichen deutschen Haushalt für die vier Einsparszenarien	36
Tabelle 20: Anzahl an Haushalten im Quartier, welche nötig sind um eine negative CO ₂ e Bilanz zu erzielen	37
Tabelle 21: Vergleich der Energiemenge der Grundlast und der mittleren Tageslast für die Zeiträume vor und nach Einführung der App in den drei Test-Haushalten	38
Tabelle 22: Beispielhafte Tageslastprofile H6 eines Tages vor der neuen Anschaffung (2024) und eines Tages nach der neuen Anschaffung (2025)	39
Tabelle 23: Vergleich der Energiemenge der Grundlast und der mittleren Tageslast für die Zeiträume vor und nach Einführung der App in Haushalt 6	39
Tabelle 24: Nutzungszeiten energieintensiver flexibler Verbraucher vor und nach Einführung der App	40
Tabelle 25: Geschäftsmodelle inklusive der profitierenden Zielgruppen und einer Einschätzung zur Wirtschaftlichkeit	45
Tabelle 26: Abstimmung der Befragten zum Thema Datenzugriff; Antwortmöglichkeiten: 1 = Ich wäre überhaupt nicht bereit. 2 = Ich wäre eher nicht dazu bereit. 3 = Ich bin unentschieden. 4 = Ich wäre bereit dazu. 5 = Ich wäre sehr bereit dazu	55

1 Allgemeine Projektangaben

1.1 Kurzbeschreibung und Voraussetzungen des Vorhabens

Das Verbundvorhaben „EVEKT - Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien und daten-basierte Mehrwertdienste“ startete im Juli 2022 im Rahmen der anwendungsorientierten nichtnuklearen Forschung und Entwicklung im 7. Energieforschungsprogramm der Bundesregierung „Innovationen für die Energiewende“ im Förderbereich „Energiewende und Gesellschaft“ (FKZ 03EI5234A). Es handelte es um eine interdisziplinäre Zusammenarbeit zwischen Beteiligten aus den Bereichen der ingenieurtechnischen Forschung, Rechts- und Sozialwissenschaften und der Industrie. Die Idee für das Projekt EVEKT entstand auf Basis der vorherigen, durch das BMWi geförderten Forschungsprojekten „Herzo Base - Energiespeicherhäuser - Ein energieflexibles Gebäude- und Energiekonzept von morgen“ (FKZ: 03ET1364A) und „Herzo Opt - Monitoring der Gebäudehülle, des thermischen Raumkomforts und der Anlagentechnik mit Betriebsoptimierung“ (FKZ: 03ET1641A). Diese umfassten die Planung, Errichtung, Betriebsoptimierung und das Langzeit-Monitoring eines Reihenhauskomplexes mit acht Wohneinheiten im Plusenergiestandard (KfW-Effizienzhaus-Standard 40 Plus gemäß EnEV 2016) in Gemeindeteil Herzo Base der Stadt Herzogenaurach. Zu Monitoring-Zwecken wurden Sensoren zur Erfassung der Stromerzeugung und -Verbrauch an verschiedenen Punkten des Gebäudekomplexes installiert, einschließlich des Gesamtverbrauchs jedes Haushalts sowie der Stromverbrauch bestimmter elektrischer Komponenten im Haushalt, wie die Lüftung oder die Wärmepumpe für die Trinkwarmwasserzubereitung.

Seit 2017 werden alle acht Wohneinheiten bewohnt. Ihr Verbrauchsmuster wurde seitdem mit einem Intervall von 15-min erfasst und gespeichert. Das Projekt EVEKT entstand als Anschlussprojekt dieser zwei Projekte. Das kommende Smart Meter Rollout hat hier als Motivation gedient, da dies zu der Erhebung von einer enormen Menge an Daten führen wird. Die erfassten Monitoring-Daten im Herzo Base Reihnhaus werden hierbei verwendet um zu untersuchen, welche Verwertungsmöglichkeiten gibt es, um datenbasierte Mehrwertdienste zu entwickeln und durch die Entwicklung einer Pilotanwendung eine aktive Beteiligung der Endnutzer an der Energiewende zu ermöglichen.

Hauptziel des Projektes EVEKT ist es, Privathaushalte durch die Umsetzung von fortschrittlichen technologischen Lösungen und KI-Technologien sowie ideellen und monetären Anreizen für die Vorteile energetisch positiven Stromkonsums zu sensibilisieren und dadurch eine aktive Beteiligung an der Energiewende auf kurz-, mittel- und langfristige Sicht zu fördern. Zu diesem Zweck wurde eine benutzerfreundliche browserbasierte Webanwendung entwickelt, die Energiedaten aus den Haushalten verarbeitet und transparent darstellt. Sie bietet den Nutzern detaillierte Einblicke in ihrem Stromverbrauch sowie eine ökonomische und energetische Bewertung ihres Verbrauchsmusters, einschließlich

eines CO₂-Scoring Konzepts. Zudem wurden KI-Algorithmen eingesetzt, welche den gesamten Haushaltsverbrauch nach einigen einzeln erkennbaren Verbrauchern aufschlüsseln und somit spezifische, die einzelnen Verbraucher betreffende, Empfehlungen zum Energie sparen geben können. Die Motivatoren werden so umgesetzt, um der nach einer Weile eintretenden Technikmüdigkeit entgegenzuwirken. Der Fokus liegt hierbei klar auf der Erfassung und Einsparung elektrischer Energie. Heizenergie wird nur am Rande betrachtet. Die entwickelte Technologie (mit TRL 6) wurde im Reihenhauskomplex Herzo Base, in einer Pilotanwendung in drei Haushalten getestet. Dabei wurde ihre Funktionsfähigkeit demonstriert. Zudem wurden die Möglichkeiten und Grenzen der positiven Beeinflussung des Konsumverhalten durch Machine-Learning-Algorithmen untersucht.

Durch die Durchführung einer sozialen Studie vom Projektpartner OTH Regensburg wurden die Nutzer in verschiedene Verbrauchergruppen unterteilt und für jede Gruppe die passenden Motivatoren identifiziert, welche eine dauerhafte Motivation zur Nutzung und Teilnahme an Einsparmaßnahmen ermöglichen. Die Ergebnisse der Studie bilden die Basis für eine Technikfolgeabschätzung und Untersuchung der Nutzerakzeptanz.

Ein weiterer Fokus liegt auf der rechtlichen Aufklärung der entwickelten Technologie durch den Projektpartner Uni Regensburg. Die entwickelte Technologie wird aus juristischer bzw. rechtswissenschaftlicher Sicht bewertet, um die datenschutzrechtliche Zulässigkeit der Datenverarbeitungsvorgänge sicherzustellen. Zudem wird untersucht, welche Informationspflichten nach Art. 13 DS-GVO gegenüber den Nutzern bestehen.

Die technische Hochschule Nürnberg Georg Simon Ohm ist für das Teilvorhaben „Energie monitoring privater Haushalte zur Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien“ zuständig. Dies umfasst die Konzeption, Entwicklung, technische Umsetzung und Evaluation der technologischen Lösungen und der dazugehörigen Komponenten, sowie die Konzeption und Bewertung potenzieller datenbasierter Mehrwertdienste. Gleichzeitig übernimmt die TH Nürnberg die Leitung des Projektes und ist daher verantwortlich für die Koordination und die Sicherstellung einer reibungslosen Zusammenarbeit zwischen den Projektpartnern. Das Projektkonsortium hat einstimmig entschieden, dass jeder Projektpartner einen eigenen Abschlussbericht erstellt und einreicht. Daher konzentriert sich der vorliegende Abschlussbericht auf die Arbeit und Ergebnisse der Technischen Hochschule Nürnberg Georg Simon Ohm im Rahmen ihrer Zuständigkeiten.

Im Rahmen des Projekts wurde ein Projektbeirat eingerichtet, der sich aus Expertinnen und Experten sowie akkreditierten Partnern aus der Energiebranche zusammensetzt (eine ausführliche Liste aller Akteure findet sich unter 1.4). Der Beirat kam während der Projektlaufzeit zweimal zusammen. In diesen Sitzungen wurden die aktuellen Ergebnisse vorgestellt, diskutiert und durch praxisnahe Impulse ergänzt. Der Austausch lieferte wertvolle fachliche Einsichten für die Weiterentwicklung des Projekts.

1.2 Ausgangssituation und Stand der Technik zum Vorhabenbeginn

07/2022

Wie in Abschnitt 1.1 bereits beschrieben, hatte der Reihenhauskomplex in Herzo Base zu Beginn des Projekts bereits zwei Forschungsprojekte durchlaufen. Seit 2017 sind alle Wohneinheiten durchgängig bewohnt, und sämtliche Stromverbrauchsdaten werden im 15-Minuten-Takt erfasst. Für die Datenerfassung und Aufzeichnung der Stromwerte, sowie für die Netzwerkinfrastruktur im Gebäude ist immer noch die Fa. ProLeiT GmbH, der frühere Projektpartner aus dem Projekt Herzo Base, zuständig. Die Daten werden auf dem Server der Firma im Technikeller des Gebäudes und mithilfe deren Energiemanagementsystems gespeichert und dargestellt. Diese bestehende Mess- und Dateninfrastruktur wurde im Projekt EVEKT weiter genutzt, während die Erfassung und Speicherung der neuen Messdaten sowie die geplante Webanwendung über einen neuen Server in der Zuständigkeit des Projektpartners Eniano GmbH erfolgen. Zu Projektbeginn wurde ein Auftrag zur Einbindung des neuen Servers an die Firma Proleit vergeben.

Im Vorfeld des Projekts wurde in mehreren wissenschaftlichen Untersuchungen das Potenzial digitaler Energiesparanwendungen zur Reduktion des Stromverbrauchs in Privathaushalten identifiziert. Tabelle 1 gibt einen Überblick über vier ausgewählte Studien aus dem deutschsprachigen Raum sowie die jeweiligen Rahmenbedingungen, unter denen diese durchgeführt wurden. Dabei variieren die dokumentierten Einsparpotenziale je nach Methodik und Nutzerinteraktion erheblich – sie reichen von geringfügigen Effekten um 1 % bis hin zu deutlichen Verbrauchsreduktionen von bis zu 13,9 %.

Tabelle 1: Studien zum Energieeinsparpotenzial durch digitale Energiesparanwendungen

	Studienstandort	Jahr	Haushalte	Zeitraum	Nutzerfeedback-Inhalte	Einsparpotenzial
[1]	Deutschland	2022	1065	2 Monaten bis 4 Jahre	Live Daten: tägliche, monatliche und jährliche Verbräuche, Erkennung einzelner Geräte (disaggregiert), Zugang über Online-Portal	Discovery: 1%
[2]	Deutschland und Österreich	2011	2000	18 Monate	Internetportal, monatliche schriftliche Information	3,7%
[3]	Österreich	2014	250	1 Jahr	In-Home-Display für iPod (Echtzeit-Anzeige des Stromverbrauchs), Webportal (histori-	4,8%

					scher Vergleich, Vergleich zwischen Energieträgern, Anzeige in kWh, kg CO ₂ und Euro) + Energiemessgerät für die Steckdose; zusätzlich Auswahl verschiedener Stromtarife möglich; persönliche Energieberatung	
[4]	Deutschland	2017	650	12-14 Monate	Drei verschiedene Feedback-Systeme: Monatliche Verbrauchsinformation, Web-Portal (nahezu Echtzeit) und iPod-Feedback-App (nahezu Echtzeit mit zusätzlich disaggregierten Daten); zusätzlich zwei unterschiedliche Stromtarif-Modelle	13,9%

Bereits zum Zeitpunkt des Projektbeginns fanden Verfahren des maschinellen Lernens zur Lösung des sogenannten Disaggregationsproblems zunehmend Anwendung. Insbesondere bei hochaufgelösten Energiedaten kamen diese Methoden häufiger zum Einsatz, während Ansätze, die mit niedrig aufgelösten Daten arbeiten, seltener vertreten waren. Beispiele hierfür sind Algorithmen wie K-Nearest Neighbours (K-NN) [5], Entscheidungsbäume (Decision Trees, DT) und Support Vector Machines (SVM) [6]. In den letzten Jahren wurden zudem vermehrt tiefe neuronale Netze zur Lastdisaggregation herangezogen, die mit Daten im Minutentakt [7] oder auf Stundenbasis [8] evaluiert wurden. Hervorzuheben sind insbesondere sogenannte Sequence-to-Point-Modelle, die in mehreren Studien eine hohe Genauigkeit nachweisen konnten [8][9]. Auch generative Ansätze wie Generative Adversarial Networks (GAN) kamen zum Einsatz und wurden mit Datensätzen unterschiedlicher zeitlicher Auflösung (1-min [11], 10-min [12]) getestet. Neben klassischen ML-Verfahren wurden auch graphbasierte Methoden zur Erkennung von Lastmustern untersucht. So entwickelten Zhao et al. in [10] eine NILM-Methode auf Basis von Graph Signal Processing (GSP), die mit 1-minütigen Daten getestet wurde. Eine angepasste Variante dieses Ansatzes wurde zudem auf stündlich aggregierten Daten angewendet [8]. Darüber hinaus wurden weitere Disaggregationsmethoden wie Discriminative Sparse Coding [13], Semi-Binary Nonnegative Matrix Factorization (SBNMF) [17] sowie optimierungsbasierte Verfahren [8] ebenfalls für Daten mit niedriger zeitlicher Auflösung erprobt.

Anfang 2022 waren in Deutschland erst rund 150.000 Haushalte mit einem intelligenten Messsystem samt Smart Meter Gateway ausgestattet – deutlich weniger als in vielen anderen europäischen Ländern. [25]

Mit der BSI-Zertifizierung des ersten Smart Meter Gateways am 12. Dezember 2018 begann der iMSys-Einbau. Der offizielle Rollout folgte am 24. Februar 2020 nach Zulassung eines dritten Gateways. Klagen gegen die BSI-Verfügung führten zu einer Entscheidung des OVG Münster und gesetzlichen Anpassungen im Messstellenbetriebsgesetz (§ 19 Abs. 6 MsbG) mit Bestandsschutzregelung. Die TR BSI-TR-03109-1 v1.1 wurde überarbeitet und vom BMWi bestätigt. Am 20. Mai 2022 hob das BSI die frühere Markterklärung rückwirkend auf, bestätigte jedoch die sichere und freiwillige Nutzung zertifizierter Gateways. Gegen die Aufhebung wurde Widerspruch eingelegt. [26]

Laut MsbG ist der Einbau intelligenter Messsysteme (iMSys) ab einem Jahresstromverbrauch von über 6.000 kWh verpflichtend. Rund 5,2 Mio. Letztverbraucher sind betroffen, davon ca. 2,1 Mio. im Bereich 6.000–10.000 kWh. Bislang (Stand Anfang 2022) wurden rund 130.400 iMSys im Pflichtbereich installiert – ein Anstieg um 105.000 gegenüber dem Vorjahr. Zusätzlich wurden etwa 27.500 iMSys freiwillig bei niedrigeren Verbräuchen eingebaut. Auch moderne Messeinrichtungen (mME) wurden verstärkt verbaut: 2021 waren rund 13,6 Mio. Messlokationen damit ausgestattet (2020: 9,5 Mio.), was u. a. zu einem Rückgang der Ferraris-Zähler führte. [26]

Tabelle 2: Pflichteinbaufälle i.S.d. § 29 i.V.m. 31, 32 MsbG (für das Jahr 2021) [26]

Elektrizität: Verpflichtender Einbau i.S.d. § 29 i.V.m. 31, 32 MsbG im Jahr 2021

Stichtag 31.12.2021	Anzahl der Messlokationen			
	Gesamt	davon mit Messsystemen gem. § 19 Abs. 5 MsbG ausgestattet	davon mit modernen Messeinrichtungen i.S.d. MsbG ausgestattet	davon mit intelligenten Messsystemen i.S.d. MsbG ausgestattet
Letztverbraucher mit Jahresstromverbrauch				
> 6.000 kWh & ≤ 10.000 kWh	2.063.024	150.699	533.465	48.456
> 10.000 kWh & ≤ 20.000 kWh	1.008.656	81.966	242.313	45.432
> 20.000 kWh & ≤ 50.000 kWh	506.887	59.567	105.145	25.213
> 50.000 kWh & ≤ 100.000 kWh	152.259	39.503	19.659	4.184
> 100.000 kWh	252.439	121.186	6.290	128
Verbrauchseinrichtungen nach § 14a EnWG	1.206.337	103.350	267.905	6.537
davon Messlokationen an Ladepunkten für Elektromobile	19.203	1.406	9.692	13
Installierte Leistung bei Anlagenbetreibern gemäß § 2 Nr. 1 MsbG				
> 7 kW & ≤ 15 kW	839.060	76.008	274.121	158
> 15 kW & ≤ 30 kW	391.578	35.971	97.221	185
> 30 kW & ≤ 100 kW	206.557	37.483	32.156	60
> 100 kW	564.660	87.451	2.677	15

Tabelle 3: Optionaler Einbau i.S.d. § 29 i.V.m. 31 MsbG (für das Jahr 2021) [26]

Elektrizität: Optionaler Einbau i.S.d. § 29 i.V.m. 31 MsbG im Jahr 2021

	Anzahl der Messlokationen			
	Gesamt	davon mit Messsystemen gem. § 19 Abs. 5 MsbG ausgestattet	davon mit modernen Messeinrichtungen i.S.d. MsbG ausgestattet	davon mit intelligenten Messsystemen i.S.d. MsbG ausgestattet
Letztverbraucher mit Jahresstromverbrauch:				
≤ 2.000 kWh	23.584.414	1.737.334	6.562.381	8.218
> 2.000 kWh & ≤ 3.000 kWh	9.714.482	682.958	2.445.465	4.340
> 3.000 kWh & ≤ 4.000 kWh	6.502.334	403.660	1.574.137	1.757
> 4.000 kWh & ≤ 6.000 kWh	6.722.666	329.092	1.211.630	10.029
Installierte Leistung bei Anlagenbetreibern gemäß § 2 Nr. 1 MsbG				
> 1 kW & ≤ 7 kW	710.930	64.533	212.347	3.287

Die Kosten eines intelligenten Messsystems bestehen aus dem Smart Meter Gateway und dem digitalen Zähler. Beim Pflichteinbau trägt der Messstellenbetreiber die Anschaffungs- und Einbaukosten, während dem Verbraucher jährlich gedeckelte Nutzungsgebühren entstehen (siehe Tabelle 4). Zusätzliche Obergrenzen gelten bei bestimmten Anlagen (siehe Tabelle 5).

Tabelle 4: Kosten für den Betrieb von Smart Metern in Abhängigkeit vom jährlichen Stromverbrauch (Stand 2022) [27]

Stromverbrauch pro Jahr in kWh	maximaler Preis für den Smart Meter pro Jahr
bis 2.000	23 Euro
bis 3.000	30 Euro
bis 4.000	40 Euro
bis 6.000	60 Euro
bis 10.000	100 Euro
bis 20.000	130 Euro

Tabelle 5: Kosten für den Betrieb von Smart Metern bei dem Vorhandensein bestimmter Anlagen (Stand 2022) [27]

Art der Einrichtung/Anlage, die betrieben wird	maximaler Preis für den Smart Meter pro Jahr
steuerbare Verbrauchseinrichtung (z. B. Wärmepumpe, Nachtspeicherheizung)	100 Euro
Strom erzeugende Anlage (z. B. Photovoltaikanlage) $> 7 \leq 15$ kW	100 Euro
Strom erzeugende Anlage (z. B. Photovoltaikanlage) $> 15 \leq 30$ kW	130 Euro
Strom erzeugende Anlage (z. B. Photovoltaikanlage) > 30 kW	200 Euro

1.3 Planung und Ablauf des Vorhabens

Vor Beginn des Projekts musste sichergestellt werden, dass die Bewohner der Weiterverwendung ihrer persönlichen Verbrauchsdaten freiwillig und informiert zustimmen. Daher wurden rechtssichere Einwilligungserklärungen erstellt und verteilt. Auf diese Weise konnte die Nutzung der Verbrauchsdaten für das gesamte Gebäude gewährleistet werden. Zudem waren fünf von acht Haushalten bereit, sich aktiv am Projekt zu beteiligen – unter anderem durch die detaillierte Überwachung des Stromverbrauchs einzelner Haushaltsgeräte.

Zunächst hat die THN verschiedene KI- und Automatisierungsszenarien konzipiert. Diese wurden von der OTH zur Erstellung des Fragebogens im Rahmen ihrer sozialen Studie verwendet. Anschließend wurden quantitative Rahmenbedingungen für die Stromersparnis ermittelt und die Auswirkungen der KI- und Automatisierungsszenarien darauf abgeschätzt. Eine Methodik für die Berechnung des Strommixes des Verbrauchs und der CO₂ Emissionen im Gebäude wurde entwickelt.

Ursprünglich war es geplant, WLAN-fähige Messsteckdosen für das Intensiv-Monitoring der Haushaltsgeräte einzusetzen. Wegen aufgetretenen Problemen, vor allem bezüglich Reichweiten und Berechtigungen hat die THN in Zusammenarbeit mit der Fa. Eniano stattdessen für ein anderes Messsystem auf Basis der LoraWAN Technologie entschieden. Durch die Erstellung eines Fragebogens für die Bewohner wurden die benötigten Informationen zur Gerätenutzung erworben, welche die Basis für die Auswahl der drei Haushalte fürs das Intensiv-Monitoring geschaffen haben.

Ein Personalwechsel im Jahr 2023 aufgrund von Mutterschutz und anschließender Elternzeit sowie die nur teilzeitweise Neubesetzung der Stelle und die Entscheidung für das LoRaWAN-System führten zu Verzögerungen bei der Inbetriebnahme des Messsystems und dem Einbau der Steckdosen in den Haushalten. Diese Verzögerungen wurden zusätzlich

durch das späte Ausfüllen des Fragebogens durch die Bewohner in Herzo Base verstärkt, sodass die Inbetriebnahme erst Anfang Februar 2024 erfolgen konnte.

Die Grundfunktionen der Webanwendung wurden auf Basis der Ergebnisse der von der OTH durchgeführten sozialen Studie definiert. Ziel war es, die Nutzer zu motivieren, ihren Verbrauch zu senken oder zu flexibilisieren und gleichzeitig Technikmüdigkeit sowie den Rebound-Effekt zu vermeiden. Die Anwendung wurde von der Partnerfirma Eniano realisiert und im ersten Quartal 2025 in Betrieb genommen und steht seitdem den beteiligten Bewohnern zur Verfügung.

Durch eine umfassende Literaturrecherche wurde eine geeignete Methodik zur Identifizierung einzelner Haushaltsverbraucher ermittelt. Basierend darauf kamen drei Machine-Learning Architekturen zum Einsatz. Zudem wurde ein Algorithmus zur Erkennung der Tagesgrundlast entwickelt. Die Ergebnisse zeigen, dass die gesamte Grundlast mit geringem Aufwand und hoher Genauigkeit erfasst werden kann. Dauerhaft oder häufig genutzte Geräte wie Kühlschränke und Gefriertruhen lassen sich mit über 90 % Genauigkeit disaggregieren, während dies bei seltener genutzten Geräten wie Spül- und Waschmaschinen schwieriger war. Die Kombination des Verbrauchs solcher Geräte führte zu einer deutlichen Verbesserung der Ergebnisse. Aus diesem Grund trat die Disaggregation von einzelnen Verbrauchern für den Pilotbetrieb in den Hintergrund und wurde parallel zur Entwicklung und Evaluierung der webbasierten Benutzeroberfläche weiterverfolgt. Wichtiger wurde das zeitnahe Erkennen von Änderungen im Verbrauchsverhalten sowie Vergleiche mit Daten aus der jüngeren Vergangenheit.

Zusätzlich wurde im vierten Quartal 2024 ein neues Ziel definiert mit dem Zweck der Ermittlung von zusätzlichen praxisrelevanten Informationen aus der Disaggregation des Haushaltsstromverbrauchs und zwar die Abschätzung des Flexibilisierungspotentials des Stromverbrauchs im Haushalt durch die Ermittlung des flexiblen Anteils des Verbrauchs. Es wurde gezeigt, dass das Flexibilisierungspotential der Haushalte mit der Anwendung von Disaggregationsalgorithmen erfolgreich abgeschätzt werden kann.

Die Ergebnisse der Anwendung der Disaggregationsalgorithmen sowie die Ermittlung des Flexibilisierungspotentials wurden zur Publikation in zwei Veröffentlichungen eingereicht [33][34].

Die entwickelten Technologien und Algorithmen wurden in der Pilotanwendung in Herzo Base getestet. Durch die verspätete Bereitstellung der App, wurde die erreichbare Energieeinsparung anhand von Studien im deutschsprachigen Raum, in denen eine ähnliche Energiesparapp zum Einsatz kam, bewertet. Anhand dieser Einsparwerte wurde das System aus technischer, ökonomischer und ökologischer Sicht bewertet. Insgesamt wurde hierbei eine praxistaugliche, umweltfreundliche und potenziell kostensparende Lösung für digitale Energiesparanwendungen im Wohnquartier demonstriert.

Aufgrund des Personalwechsels und der zeitweisen Besetzung in Teilzeit sowie der verspäteten Bereitstellung der App wurde von der THN beim Projektträger ein Antrag auf kostenneutrale Verlängerung gestellt. Dieser wurde bewilligt. Dadurch wurde es ermöglicht, die Bewertung des Systems zusätzlich mit realen Einsparwerten abzuschließen.

Anhand der Bewertung der realen Daten konnte schlussendlich eine Stromverbrauchseinsparung und eine Grundlastsenkung von jeweils 7% gemessen werden und somit die mögliche Einsparung der untersuchten Studien verifiziert werden. Es wurde gezeigt, dass allein die Anzeige von Stromverbrauchsdaten und Grundlast zu einer Einsparung führen können.

Außerdem wurde die Verschiebung der Nutzung der flexiblen Verbraucher bewertet. Hierbei konnte keine signifikante Änderung der Nutzungszeiten erkannt werden, was unter anderem auf die gemeinschaftliche Nutzung der vorhandenen PV-Anlage zurückzuführen ist, wodurch eine zeitliche Verschiebung der Gerätenutzung nicht direkt finanziell entlohnt wird.

Zudem wurden mögliche Geschäftsmodelle anhand datenbasierter Mehrwertdienste entwickelt. Diese wurden auf ihre Wirtschaftlichkeit hin untersucht sowie zusätzlich eine Einschätzung zum Datenschutz gegeben.

Das AP 5 konnte gemäß dem neuen Arbeitsplan zum 31.08.2025 abgeschlossen werden.

Die THN war an der Erreichung der Meilensteine M1, M3, M5 und M7 beteiligt. Die Meilensteinberichte zu M1, M3 und M5 wurden dem ursprünglichen Zeitplan gemäß eingereicht. Der Teil des Meilensteinberichts M7, welcher von der THN bearbeitet wurde, wurde aus oben genannten Gründen nach hinten verschoben. Die Abgabe des Meilensteinberichts M7 erfolgte somit am 31.08.2025 anstatt zum 30.06.2025.

Während der gesamten Projektlaufzeit hat die THN eine enge Zusammenarbeit mit den drei Projektpartnern, sowie mit dem Administrator des Netzwerk- und Messsystems, ProLeiT GmbH gepflegt. Des Weiteren hat die THN die Kooperation zwischen Eniano und ProLeiT beim Anbindung des neuen Servers am bestehenden System erleichtert und koordiniert. Gleichzeitig hat die THN die Bewohner bei dem Einbau der Komponenten und der Verwendung der Anwendung aktiv unterstützt.

1.4 Zusammenarbeit mit anderen Stellen

Die Technische Hochschule Nürnberg pflegte während der gesamten Projektlaufzeit eine enge Zusammenarbeit mit der ProLeiT GmbH. Das Unternehmen war bereits in früheren Projekten ein zentraler Partner und verantwortet den Aufbau sowie die fortlaufende Betreuung des gesamten Gebäudenetzwerks. Dies umfasst die komplette Steuerungs- und Automatisierungstechnik des Gebäudes ebenso wie die Erfassung und Verwaltung der Messdaten in einer zentralen Datenbank. Außerdem wurde – wie bereits beschrieben – ein Projektbeirat aus Expertinnen und Experten der Energiebranche zusammengestellt. Folgende Organisationen, Unternehmen und kommunale Akteure haben ihre Mitwirkung per Letter of Intent (LoI) zugesagt und waren im Beirat vertreten:

Kommunale Energieversorger / Netzbetreiber:

- N-ERGIE
- Naturstrom AG
- HerzoWerke GmbH
- Bayernwerk Netz GmbH
- Infra Fürth
- Stadtwerke Schwabach

Kommunale und öffentliche Einrichtungen:

- Stadt Regensburg

Initiativen / Netzwerke / Organisationen:

- Energiewende ER(H)langen e.V.
- Netzwerk Internet und Digitalisierung Ostbayern (INDIGO)
- Regensburg Center of Energy and Resources (RCER)
- Energiecampus Nürnberg

2 Darstellung der Projektdurchführung

2.1 Ergebnisse des Projektes

AP 1 Vorbereiten der sozialwissenschaftlichen Begleitforschung

Das folgende Kapitel gibt einen Überblick über die zentralen im Rahmen des Arbeitspakets 1 durchgeführten Arbeiten sowie über die daraus gewonnenen Ergebnisse. Ein wesentlicher Bestandteil dieses Arbeitspakets war die enge und kontinuierliche Zusammenarbeit mit der Partnerhochschule OTH Regensburg.

AP 1.3 Entwicklung verschiedener KI- und Automatisierungsszenarien

Die THN hat verschiedenen KI- und Automatisierungsszenarien konzipiert, welche für die Erstellung des Fragebogens vom Projektpartner OTH zur Nutzung für die im Rahmen des AP2 bevölkerungsrepräsentative Nutzerbefragung verwendet wurden. Vor der Erstellung der Szenarien wurden als erstes die unterschiedlichen Zielsetzungen ermittelt. Diese sind zum einen die Energieeinsparung und zum anderen die Kosteneinsparung durch das Einsparen von Netzbezug, das Verschieben von Verbräuchen in Zeiten von PV-Strom-Erzeugung und/oder in Zeiten von niedrigen Strompreisen. Es wurden insgesamt 10 KI- und Automatisierungsszenarien erstellt, welche von Anzeige von Stromwerten bis zur automatisierten Steuerung von Haushaltsgeräten und KI-basierten Empfehlungen von Verhaltensänderungen reichen.

- Szenario 1: Anzeigemöglichkeit für Verbraucherinnen und Verbraucher
- Szenario 2: Szenario 1 mit zusätzlichem Disaggregationsalgorithmus
- Szenario 3: Szenario 1 mit zus. Kostensparhinweisen
- Szenario 4: Szenario 1 mit zus. Stromsparhinweisen
- Szenario 5: Szenario 1 mit zus. Push-Benachrichtigungen für Kostensparhinweise
- Szenario 6: Szenario 1 mit zus. Push-Benachrichtigungen für Stromsparhinweise
- Szenario 7: Szenario 1 mit zus. Push-Benachrichtigungen für Kostensparhinweise für den Betrieb von Geräten, wenn Strom aus eigener PV-Anlage verfügbar
- Szenario 8: Szenario 1 mit zus. Push-Benachrichtigungen für Kostensparhinweise für Betrieb von Geräten in Zeiten von günstigem Strom bei variablen Tarifen
- Szenario 9: Szenario 1 mit Automatisierungsmöglichkeit für steuerbare Haushaltsgeräte, wenn überschüssiger Strom aus eigener PV-Anlage verfügbar ist.
- Szenario 10: Szenario 1 mit Automatisierungsmöglichkeit für steuerbare Haushaltsgeräte, wenn in variablen Stromtarifen günstiger Strom verfügbar ist.

Von den 10 genannten Szenarien waren die Szenarien 1 bis 7 im Projekt EVEKT geplant und wurden schließlich umgesetzt, während die Szenarien 8 – 10 nur auf Machbarkeit überprüft wurden. Es ist hierbei anzumerken, dass in Herzo Base keine variablen Tarife vorhanden sind. Anschließend wurden alle Szenarien auf technische sowie wirtschaftliche

Machbarkeit überprüft, wobei die Komponenten und Algorithmen einzeln betrachtet wurden. Als erstes wurden die technische Umsetzung der Komponenten bzw. Geräte, welche für die Umsetzung der Szenarien erforderlich sind, geprüft. Diese sind das Smart Meter und die dazugehörige Ausstattung, Unterzähler zur Datenerfassung des Geräteverbrauchs, die PV-Anlage und Komponenten zur automatisierten Steuerung von Haushaltsverbrauchern. Die sind bereits Stand der Technik und im Markt verfügbar (z.B. Schaltgeräte, Unterzähler) und zum Teil in der technischen Ausstattung des Projekt-Reihenhauskomplexes schon vorhanden (Smart Meter, PV-Anlage).

Ebenso wurde festgestellt, dass Anzeigemöglichkeiten und Apps, welche den Energieverbrauch anzeigen, bereits Stand der Technik und vielfach verfügbar sind, was eine technische Umsetzung ermöglicht. Auch die Algorithmen zur Ermittlung von personalisierten Empfehlungen wurden bereits in vielerlei wissenschaftlichen Arbeiten untersucht. Eine Einschränkung hier war die niedrige Auflösung (15 min) der Smart-Meter-Daten. Dies wurde im Laufe des AP 3.2 untersucht und wird im entsprechenden Abschnitt diskutiert. Schlussendlich wurde festgestellt, dass alle Szenarien technisch und wirtschaftlich unter vertretbarem Aufwand machbar sind. Folglich sind keine der im Projektantrag definierten Abbruchkriterien erfüllt.

AP 1.4 Quantitative Rahmenbedingungen

Im Rahmen des AP 1.4 wurden die Bewertungskriterien zur Verhaltensänderung festgestellt. Diese sind die el. Energieeinsparung, CO₂e-Einsparung und Kosteneinsparung. Folgende Zielfunktionen für die Bewertung von Verhaltensänderungen wurden definiert:

1. Generelle Stromeinsparung
2. Kosteneinsparung durch eine Lastverschiebung in Zeiten von günstigem Strom
3. El. Energie- bzw. CO₂e-Einsparung durch eine Lastverschiebung in Zeiten von hoher PV-Eigenproduktion bzw. in Zeiten hoher regenerativen Stromerzeugung
4. Netzdienliches Verhalten durch die Verschiebung von Lasten von Hoch- in Niedriglastzeiträume des lokalen Netzes

Für die Herzo Base Energiehäuser sind die Varianten 1,3 und 4 relevant, da kein variabler Stromtarif zur Verfügung steht. Anschließend wurde für jedes in AP 1.3 definierte Szenario eine kurze Einschätzung des Einflusses von KI- und Automatisierungstechnologien auf CO₂e-/Strom-/Kosteneinsparungen ermittelt. Die verschiedenen Szenarien sowie ihr Einfluss auf CO₂e-/Strom-/Kosteneinsparungen befinden sich im Anhang A. Wie auch im Hintergrundpapier Künstliche Intelligenz für die Energiewende: Chancen und Risiken von Germanwatch e.V. beschrieben [19], zeigt sich: Je genauer und aufgliederter dem Nutzer sein Energieverbrauch dargestellt wird, desto leichter fällt es ihm, daraufhin spezielle Energiesparmaßnahmen zu ergreifen.

Um Veränderungen im Stromverbrauchsverhalten zu bewerten, wurden verschiedene Zeitintervalle festgelegt und einzeln untersucht. Da die Verbrauchsdaten alle 15 Minuten erfasst wurden, zeigen sich kurzfristige Schwankungen, die auf zufälliges Nutzerverhalten zurückzuführen sind. Je länger das Zeitintervall ist desto mehr werden die Zufallseinflüsse reduziert. Die Entscheidung fiel auf ein Zeitintervall von vier Stunden. Dafür gibt es zwei Hauptgründe: Erstens würde ein längerer Zeitraum keine präzisen oder hilfreichen Informationen für die Bewohner liefern. Zweitens orientiert sich die Einteilung in vierstündige Abschnitte am typischen Tagesablauf der Bewohner. So lassen sich beispielsweise die Zeit von 8 bis 12 Uhr (Vormittag, Homeoffice oder Abwesenheit), von 12 bis 16 Uhr (Mittagessen, Kochen) und von 16 bis 20 Uhr (Nachmittags- und Abendaktivitäten) sinnvoll voneinander abgrenzen. Der Stromverbrauch des jeweiligen Zeitintervalls wird mit dem „üblichen“ Stromverbrauch von vergangenen vergleichbaren Tagen verglichen. Dieser „übliche“ Stromverbrauch wird vom Mittelwert der gleichen Zeiträume der 10 vorherigen Tagen ermittelt.

Eine weitere Arbeit im Rahmen des AP 1.4 war die Schaffung einer Berechnungsgrundlage zur Ermittlung des CO₂-Scores. Zu diesem Zweck sollte als erstes eine Methode zur Berechnung des Strommixes des Haushaltsverbrauchs entwickelt werden. Im Fall von Herzo Base teilt sich der Strommix auf in netzbezogenen, aus der PV-Anlage direktbezogenen und batteriebezogenen Strom. Ein besonderes Merkmal der Energiespeicherhäuser in Herzo Base ist, dass sowohl die Photovoltaikanlage als auch der Batteriespeicher gemeinschaftlich von allen Haushalten genutzt werden. Dadurch gestaltet sich die Ermittlung des individuellen Strommixes pro Haushalt komplexer. Diese soll indirekt durch die Auswertung der Messdaten von Stromzählern an verschiedenen Punkten innerhalb des Stromnetzes des Gebäudes erfolgen. Hierfür wurde ein Berechnungsmodell entwickelt, das auf den 15-Minuten-Messwerten der Lastgangzähler für die PV-Anlage, der Batterie, des Netzanschlusspunktes sowie der einzelnen Haushaltszähler basiert. Der Strommix wird vor allem für die Ermittlung des CO₂-Scores für jeden Haushalt verwendet. Abbildung 1 zeigt den berechneten Strommix des gesamten Gebäudes für vier Jahre.




Abbildung 1 Jahresstrommix des gesamten Gebäudes in Herzo Base von 2019 bis 2022

Der CO₂-Ausstoß [g/kWh] jedes Haushalts wurde entsprechend der genutzten Energiequelle berechnet. Für die Berechnung wurden auch andere treibhauswirksame Gase in Form ihres CO₂e-Äquivalents (CO₂e) berücksichtigt. Die Emissionen durch die gesamte Lebenszyklusanalyse (Vorkette) des aus der PV-Anlage direktbezogenen Stroms werden ebenso berücksichtigt. Aufgrund des Mangels an Daten wurden die Vorkettenemissionen des Batteriespeichers nicht angerechnet, sondern nur die Batterieverluste mit den Emissionszahlen des Ladestroms. Zur Bestimmung der Emissionszahlen des netzbezogenen Stroms wurden zwei Alternativen berücksichtigt: Zum einen der marktbasierter Ansatz, bei dem die Emissionsfaktoren aus dem Strommix des jeweiligen Stromvertrags abgeleitet werden, und zum anderen der ortsbasierte Ansatz, bei dem die Emissionsfaktoren auf dem im örtlichen Netz vorherrschenden Strommix beruhen. Beim marktbasierter Ansatz fällt bei Ökostrom mit 0 t CO₂e-Emissionen der Anreiz zum Stromsparen weg. Stattdessen könnte ein Rebound-Effekt auftreten. Auch eine Lastverschiebung in PV-reiche Zeiten würde hier die CO₂e-Bilanz verschlechtern. Deshalb wurde der ortsbasierte Ansatz gewählt. Tabelle 6 zeigt die Emissionen in g/kWh für die genannten Energiequellen. Mithilfe dieser Emissionsfaktoren wurden die CO₂e-Emissionen pro 15 min für jeden Haushalt berechnet (Tabelle 7). Falls keine regionalen Emissionsdaten vorliegen, kann auf den deutschen Strommix zurückgegriffen werden.

Tabelle 6: Treibgasemissionen der verschiedenen Energiequellen des verbrauchten Stroms in Herzo Base [16][21]

Energiequelle	CO ₂ e-Emissionen inkl. Vorkette [g/kWh]
---------------	---

Stromnetz	498
PV-Anlage	56,55
Batteriespeicher	56,6 +56,55/0,78

Tabelle 7: CO₂e-Emissionen pro Haushalt in Tonnen zwischen 2019 und 2022

	2019	2020	2021	2022
HH 1	0,73	0,76	0,86	0,92
HH 2	0,80	0,89	1,08	1,19
HH 3	0,96	1,04	1,16	1,36

AP 3 Entwicklung KI-basierter Algorithmen

Im folgenden Kapitel werden die wichtigsten Arbeiten beschrieben, die im Rahmen des Arbeitspakets 3 durchgeführt wurden, sowie die daraus resultierenden Ergebnisse. Besonders hervorzuheben über den gesamten Verlauf dieses Arbeitspakets ist die Kooperation zwischen der THN und der Firma Eniano, die eine kontinuierliche Abstimmung zu Hardwarefragen, zur Einrichtung und zum Betrieb des Messsystems sowie zur Datenerfassung ermöglichte. In gemeinsamer Abstimmung entwickelten THN und Eniano zudem die Struktur der webbasierten Benutzeroberfläche für die Nutzerinteraktion. Ergänzend erfolgte eine enge Zusammenarbeit mit der OTH, die ihre fachliche Expertise in die inhaltliche Ausgestaltung der App einbrachte, insbesondere im Hinblick auf nutzerorientierte Hinweise und Empfehlungen.

AP 3.1 Konzeption, Aufbau und Betrieb der Systemkomponenten

Im Rahmen des Arbeitspaketes 3.1 war ein Server vorgesehen, der als Middleware zur Anbindung des Messsystems dient und zugleich das browserbasierte Nutzerinteraktionssystem samt zugehöriger Algorithmen bereitstellt. Der Server wurde von der THN bestellt und gemeinsam mit dem Projektpartner ENIANO in der Technikzentrale des Gebäudes in einem neuen Rack aufgestellt (Abbildung 2). Die Firma ProLeiT GmbH, welche das Gebäudenetzwerk im Rahmen vorheriger Projekte aufgebaut hat und seither administriert, wurde beauftragt, den neuen Server in das bestehende System zu integrieren. Dazu wurde der neue Server an den vorhandenen V-LAN Switch angeschlossen und der entsprechende Port im Netzwerk freigegeben. Die Tests auf grundlegende Funktionalität waren erfolgreich.



Abbildung 2: Aufgestellter Server im Rack in der Technikzentrale des Gebäudes

Nach der Einbindung des neuen Servers wurde eine Liste mit detaillierten Beschreibungen aller Kennungen der im bestehenden System eingebauten Strom- und Temperaturzähler sowie weiterer Sensoren vervollständigt und dem Projektpartner Eniano übergeben. Auf Grundlage dieser Liste wurden sämtliche bestehenden Messpunkte auf dem neuen Server aufgerufen, gespeichert und werden seither direkt von dort abgerufen.

Tabelle 8: Verteilung der Messsteckdosen in den ausgewählten Haushalten

H1	H2	H3
Waschmaschine	Waschmaschine	Waschmaschine
Geschirrspüler	Geschirrspüler	Geschirrspüler
Kühlschrank	Trockner	Trockner
	Kühlschrank 1	Kühlschrank 1
	Kühlschrank 2	Kühlschrank 2
		Gefriertruhe
		Staubsauger EG

Eine weitere Arbeit im Rahmen des AP 3.1 war die Bestimmung der drei Haushalte, welche in das detailliertere Monitoring einbezogen und mit zusätzlichen Messgeräten ausgestattet werden sollen. Wie schon im Abschnitt 1.3 beschrieben, erklärten sich fünf der acht Haushalte bereit, aktiv am Projekt mitzuwirken. Ein Fragebogen zur Gerätenutzung wurde

erstellt, in dem unter anderem die Nutzung der Haushaltsgeräte, das Verbraucherverhalten und die Gewohnheiten der Haushaltsmitglieder erfragt wurden. Der Fragebogen diente sowohl der Auswahl der drei Haushalte als auch der Auswahl der Haushaltsgeräte, die intensiv überwacht werden sollten. Die Auswahlkriterien der Haushalte umfassten Unterschiede im Stromverbrauch, der Personenanzahl und den Gewohnheiten. Die Haushaltsgeräte mit dem vermuteten höchsten Jahresverbrauch wurden für das Intensiv-Monitoring ausgewählt. Insgesamt wurden 15 Messsteckdosen auf die Haushalte verteilt, wie in Tabelle 8 beschrieben.

In der Vorhabenbeschreibung war vorgesehen, WLAN-fähige Messsteckdosen in das bestehende vor Ort System zu integrieren, um die Haushaltsgeräte zu überwachen. Aufgrund wiederholter Probleme mit der Reichweite, den Berechtigungen und unvorhersehbaren Störungen des Systems wurde jedoch beschlossen, ein alternatives Kommunikationssystem zu entwickeln. Auch die ursprüngliche Überlegung, Steckdosenzähler auszuwählen, die in Verbindung mit dem im Herzo Base installierten PV-System eine Steuerung der angeschlossenen Geräte basierend auf der aktuellen PV-Erzeugung ermöglichen, wurde verworfen. Der Grund dafür war die technische Schwierigkeit, Messdaten von solchen handelsüblichen Steckdosenzählern zuverlässig abzurufen. In Übereinstimmung mit dem Projektpartner ENIANO wurde schließlich ein Messsystem auf Basis der LoRaWAN-Technologie ausgewählt. Das LoRaWAN System ist der neue Branchenstandard in der Energiewirtschaft. Das eingebaute System besteht aus Messsteckdosen, die drahtlos über das LoRaWAN-Netzwerkprotokoll mit einem Gateway kommunizieren. Eine Antenne zum Empfang der Messsignale ist ebenfalls Bestandteil des Systems. Das Gateway wurde direkt in den neuen Server in Herzo Base eingebunden. Dadurch waren keine Anpassungen am bestehenden Netzwerksystem notwendig, was gleichzeitig die Fehleranfälligkeit verringerte. Ein Aufbaukonzept in der Energiezentrale wurde entwickelt. Anschließend wurde das Messsystem in der Technikzentrale erfolgreich getestet und in Betrieb genommen. Die durch die Änderung des ursprünglich geplanten Systems bedingten zeitlichen Verzögerungen sowie die verspätete Rückgabe des Fragebogens durch die Bewohner führten dazu, dass die Inbetriebnahme erst im Februar 2024 erfolgen konnte. Seitdem wird der Gerätverbrauch jede Minute erfasst, auf dem Server gespeichert und kontinuierlich ausgewertet. Die Kosten für das gesamte LoRaWAN-System blieben jedoch im Budgetrahmen des ursprünglich geplanten Systems.

AP 3.2: Methodische Entwicklung und Implementierung der Algorithmen

Im Rahmen dieses Arbeitspakets sollte ein passendes Verfahren zur Analyse des Stromverbrauchs der Haushalte entwickelt und umgesetzt werden, um den Verbrauch der Grundlast sowie einzelner elektrischer Geräte zu erkennen und zuzuordnen. Eine umfassende Literaturrecherche wurde durchgeführt mit dem Ziel eine geeignete Methode zu identifizieren, welche mit den Eigenschaften typischer Smart-Meter-Daten, wie sie in den

Energiespeicherhäusern der Herzo Base vorliegen, kompatibel ist. Der entsprechende Bericht wurde als Anhang zum dritten Zwischenbericht beigelegt. Ein zentrales Ergebnis der Recherche war, dass die Mehrzahl der in der Fachliteratur beschriebenen Disaggregationsverfahren auf hochauflösende Leistungsdaten (≤ 1 Sekunde) angewiesen sind oder zusätzliche Parameter wie Blindleistung, Stromstärke, Spannung oder Wetterinformationen benötigen. Nur wenige Ansätze sind darauf ausgelegt, allein auf Basis aggregierter Haushaltsenergiedaten mit einer Auflösung von mindestens einer Minute zu arbeiten – eine Anforderung, die dem Standard der in Herzo Base eingebaute Smart Meter entspricht, welche Verbrauchsdaten im 15-Minuten-Takt erfassen. Diese Auflösung wird jedoch zukünftig auch bei Smart Metern Rollout gängige Praxis sein. Diese relativ grobe Datenauflösung erschwert insbesondere die Identifikation von Geräten mit kurzer und unregelmäßigen Nutzungsdauer, wie z.B. Waschmaschinen oder Geschirrspüler. Solche Geräte wurden im Rahmen des Projekts als zeitlich verschiebbar eingestuft und bezüglich ihrer Nutzung auch die entsprechenden Hinweise definiert (siehe AP 3.3). Im Gegensatz dazu lassen sich kontinuierlich oder regelmäßig arbeitende Geräte – wie beispielsweise Kühlschränke – deutlich zuverlässiger erkennen. Das gleiche gilt für die gesamte Grundlast des Haushalts. Auf Basis dieser Erkenntnisse wurde beschlossen, den gesamten Stromverbrauch eines Haushalts in zwei Kategorien zu unterteilen: einen flexiblen und einen nicht-flexiblen Anteil.

Aus diesem Grund wurde im Rahmen des Pilotbetriebs der Anwendung entschieden, den Nutzerinnen und Nutzern die disaggregierten Daten einzelner Geräte nicht direkt anzuzeigen. Da die Genauigkeit der Disaggregation in diesem Bereich nicht zufriedenstellend war, hätte eine detaillierte Darstellung einzelner Verbraucher zu Missverständnissen führen können. Stattdessen wurden gerätespezifische Nutzungshinweise direkt aus den gemessenen Verbrauchsdaten abgeleitet und in verständlicher Form bereitgestellt – ohne eine vollständige, potenziell fehleranfällige Disaggregation. Die Entwicklung und Bewertung der webbasierten Benutzeroberfläche berücksichtigte diesen Ansatz und stellte die nutzerfreundliche Darstellung relevanter Verbrauchsinformationen in den Vordergrund. Darüber hinaus wurde ein zusätzliches Ziel formuliert: Es soll untersucht werden, welche weiteren praxisnahen Erkenntnisse durch die detaillierte Analyse des Haushaltsstromverbrauchs gewonnen werden können. Insbesondere soll das Potenzial zur zeitlichen Flexibilisierung im Stromverbrauch von Haushalten eingeschätzt werden. Dies geschieht durch die Analyse und Messung des flexiblen Verbrauchsanteils, der aus der Verbrauchserlegung hervorgeht.

Als erstes wurde der nicht-flexiblen Anteil bestimmt. Eine Methode zur Berechnung der Tagesgrundlast wurde entwickelt und erfolgreich getestet. Eine Genauigkeit von über 96% für alle 3 Haushalte wurde mithilfe der Verbrauchsdaten während der Urlaubszeiten ermittelt (Abbildung 3). Das Dokument zur Grundlastberechnung wurde dem dritten Zwischenbericht beigelegt.

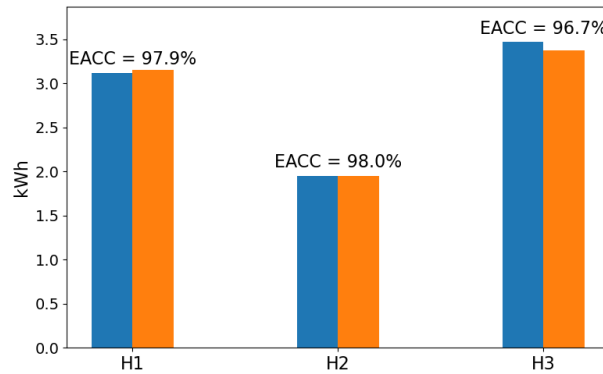


Abbildung 3: Berechnete mittlere Tagesgrundlast (orange) und mittlerer Tagesverbrauch (blau) während der Urlaubszeiten

Für die Erkennung des Verbrauchs einzelner Geräte, die dem nicht-flexiblen Anteil des Haushaltsverbrauchs zugeordnet werden (z. B. Kühl- und Gefrierschränke), wurden auf Basis der Literaturrecherche drei Methoden des maschinellen Lernens ausgewählt, die als besonders vielversprechend für die Disaggregation von Energiemessdaten mit niedriger Auflösung gelten (Seq2Point [9], EnerGAN [11], IMG-NILM [20]). Der Zeitraum wurde in 8-Stunden-Fenster unterteilt, um verwertbare und relevante Ergebnisse zu erhalten. Ziel war es, festzustellen, ob die Geräte in Zeiten hoher Netzbelastung oder bei erhöhter Erzeugung erneuerbarer Energie betrieben wurden. Alle drei Algorithmen haben vergleichbare Ergebnisse geliefert und konnten den Verbrauch der Kühl- und Gefrierschränke mit einer Genauigkeit über 90 % identifizieren (Tabelle 9 und Abbildung 4).

Tabelle 9: E_{Acc} and M_R (8-Stunden Fenster) (E_{Acc}/M_R) für die Kühl- und Gefriergeräte in den drei Haushalten. KS: Kühlschrank, GT: Gefriertruhe

	H1		H2		H3	
Device	KS	KS1	KS2	KS1	KS2	GT
IMG-NILM	0.92/0.85	0.92/0.84	0.89/0.78	0.92/0.86	0.92/0.84	0.97/0.93
Seq2Point	0.92/0.86	0.93/0.86	0.89/0.79	0.92/0.86	0.88/0.77	0.96/0.93
EnerGAN	0.91/0.82	0.88/0.78	0.88/0.77	0.89/0.78	0.89/0.77	0.93/0.87




Abbildung 4: Disaggregationsergebnisse für die Kühl- und Gefriergeräte in den Haushalten

Die oben erwähnte Analyse hat gezeigt, dass der nicht-flexible Stromverbrauch in Haushalten mit einer Genauigkeit von über 90 % ermittelt werden kann. Dies ist allein auf Basis der im Rahmen des Smart-Meter-Rollouts vorgesehenen 15-Minuten-Messdaten möglich, ohne dass zusätzliche Sensorik oder Messaufwand erforderlich ist. Den Haushalten können so mit minimalem Aufwand hilfreiche Einblicke in diesen konstanten Verbrauchsanteil bereitgestellt werden. Es wird erwartet, dass eine solche Transparenz langfristig zu einem bewussteren Umgang mit Energie und somit zu einer Reduktion des gesamten Stromverbrauchs führt.

Die drei Maschine-Learning-Algorithmen wurden auch für die Ermittlung des flexiblen Anteils des Haushaltsverbrauchs (Wasch- und Spülmaschinen, Wäschetrockner) (siehe Tabelle 8) eingesetzt. Der Seq2Point Algorithmus konnte am genauesten die verbrauchte Energie disaggregieren (Abbildung 5). Eine Disaggregationsgenauigkeit von 53,9% wurde über alle Haushalte und Geräte hinweg erreicht (Tabelle 10).

Tabelle 10: E_{Acc} und M_R Werte (8-Stunden Fenster) für die kurzzeitig intensiven Stromverbraucher in den Haushalten H1, H2 und H3, WM: Waschmaschine, GS: Geschirrspüler und WT: Wäschetrockner

	H1			H2			H3	
Device	GS	WM	WT	WM	GS	WT	WM	
IMG-NILM	0.53/0.2	0.11/0.05	0.52/0.3	0.51/0.3	0.35/0.2	0.28/0.3	0.48/0.3	
Seq2Point	0	-/0.02	1	8	9	2	6	
EnerGAN	0.8/0.7	-/0.02	9	8	0.59/0.4	0.64/0.3	0.53/0.3	
			4	4	2	7	2	
	0.55/0.1	0.48/0	0.49/0.0	0.50/0.0	0.56/0.3	0.67/0.4	0.50/0.1	
	5		4	4	7	4	5	




Abbildung 5: Disaggregationsergebnisse für die kurzzeitig intensiven Stromverbraucher in H1, H2 und H3 Haushalten

Die Kombination des Verbrauchs mehrerer flexibler Geräte konnte die Genauigkeit auf 72 % erhöhen – ein klarer Fortschritt gegenüber den vorherigen Ergebnissen (Tabelle 11).

Tabelle 11: E_{Acc} und M_R Werte (8-Stunden Fenster) für die kumulierten intensiven Stromverbraucher in H1, H2 und H3

	H1 (GS+WM)		H2 (WM+WT)		H3 (GS+WM+WT)	
	E_{Acc}	M_R	E_{Acc}	M_R	E_{Acc}	M_R
IMG-NILM	0.60	0.32	0.64	0.44	0.61	0.53
Seq2Point	0.66	0.56	0.59	0.48	0.81	0.70
EnerGAN	0.67	0.43	0.68	0.39	0.81	0.66

Die oben genannten Ergebnisse wurden in einer wissenschaftlichen Publikation mit dem Titel „Motivating households to adopt climate-friendly behavior by using smart meter data and AI technologies“ ausführlich beschrieben. Diese Publikation wurde als Tagungsbeitrag für die Konferenz „REHVA HVAC World Congress CLIMA 2025“ in Mailand eingereicht. Sie ist dem vorliegenden Bericht als separates Dokument beigelegt (Anhang B). [33]

Außerdem wurde es, wie bereits erwähnt, im Rahmen des zusätzlichen Zieles untersucht, ob und mit welcher Genauigkeit das Flexibilisierungspotential der Haushalte mit der Anwendung von Disaggregationsalgorithmen abgeschätzt werden kann. Zu diesem Zweck wurde ein Zeitfenster von 24 Stunden definiert. Es wurde gezeigt, dass das Flexibilisierungspotential, entweder durch das Herausfiltern des nicht-flexiblen Anteils vom Gesamtverbrauch oder durch die direkte Disaggregation der flexiblen Haushaltsverbraucher, mit hoher Genauigkeit abgeschätzt werden kann. Die abgeschätzten verschiebbaren und daher flexiblen Verbrauchsanteile sind sehr individuell und variieren für die drei beispielhaft ausgewählten Haushalte zwischen 6,9% für Haushalt H1 mit dem niedrigsten

absoluten Verbrauch und einem sparsameren Verhalten bis zu 39,4% bei Haushalt H3 mit hohem Verbrauch und häufig verwendeten Haushaltsgeräten (Abbildung 6).




Abbildung 6: Disaggregationsergebnisse für den gesamten Verbrauch der kumulierten intensiven Stromverbraucher in H1, H2 und H3

Auf Grundlage der oben dargestellten Ergebnisse wurde eine wissenschaftliche Publikation mit dem Titel ‚Methodik zur Abschätzung des Flexibilisierungspotentials von Haushaltsverbrauchern in elektrischen Netzen‘ verfasst und als Beitrag zum ETG Kongress 2025 der energietechnischen Gesellschaft im VDE in Kassel eingereicht. Die Publikation ist diesem Bericht als separates Dokument im Anhang C [34] beigelegt.

Beide genannte Beiträge [33] und [34] wurden auf Konferenzen präsentiert und werden unter IEEE und Springerlink veröffentlicht.

AP 3.3: Konzeption, Implementierung und Betrieb intelligenter Nutzerinteraktionssysteme

Die THN hat im Rahmen dieses APs die Grundfunktionen der browserbasierten Web-Anwendung definiert. Ein Dokument mit der ausführlichen Beschreibung der Funktionen der entwickelten browserbasierten Anwendung wurde dem vierten Zwischenbericht beigelegt. Die definierten Funktionen sind folgende:

1. Aufteilung des Tages in Intervalle
2. Berechnung und Anzeige des Haushaltsverbrauchs im letzten Intervall
3. Vergleich des Verbrauchs im letzten Intervall mit vergangenen ähnlichen Tagen
4. Berechnung und Anzeige des Strommixes des Haushalts
5. Berechnung des CO₂-Scores des Haushalts
6. Vergleich des CO₂-Scores mit dem CO₂-Score der letzten Tage
7. Bewertung und Anzeige des CO₂-Scores
8. Berechnung und Anzeige der Stromkosten für das letzte Intervall (4h)
9. Erkennung der gesamten Grundlast des Haushalts
10. Berechnung des Anteils der Grundlast am Tagesverbrauch

11. Vergleich der Grundlast des letzten Tages mit der Grundlast von vergangenen Tagen
12. Anzeige des Verbrauchs der Trinkwarmwasser-Wärmepumpe
13. Erkennung von Urlaubszeiten bzw. Zeiten langer Abwesenheit
14. Berechnung und Anzeige des täglichen Verbrauchs der Haushaltsgeräte
15. Erkennung der Betriebszeiten der Waschmaschine, Geschirrspülers und Wäschetrockners
16. Energiespartipps und Kostenspartipps / Verhaltenstipps
 - Wetterspezifische Hinweise
 - Spartipps anhand der bisherigen Nutzung von Waschmaschine, Spülmaschine und Trockner
 - Allgemeine Spartipps
 - Tipps zur effizienten Nutzung der Haushaltsgeräte
 - Zusätzliche Spartipps für die Herzo Base Energiespeicherhäuser

Die Funktionen wurden unter Berücksichtigung der Ergebnisse von [3], [4], [5], [6], [7], [8], [9] sowie der Umfrage, bei ca. 2000 repräsentativen Stromkunden durch den Projektpartner OTH im Rahmen des Arbeitspakets 2.2 befragt wurden [13], entwickelt. Wie schon unter AP1.4 beschrieben, wurde der Tag in sechs Intervalle von je vier Stunden aufgeteilt (0-4, 4-8, 8-12, 12-16, 16-20, 20-24). Die Bewohner können verschiedene Werte bezüglich ihres Stromverbrauchs einsehen, darunter der Haushaltsverbrauch und der Strommix im letzten Intervall, sowie der CO₂e-Score und die Grundlast des letzten Tages. Ein Vergleich dieser Werte mit vorherigen, ähnlichen Tagen steht auch zur Verfügung. Dabei lag der Fokus darauf, nur die wesentlichsten Kennzahlen in verständlicher Form zu präsentieren und eine Überflutung mit Informationen zu vermeiden. Das Ziel ist, die Bewohner gezielt auf alle relevanten Informationen hinzuweisen und sicherzustellen, dass Veränderungen im Verbrauch – insbesondere Anstiege – nicht unbemerkt bleiben. Anschließend wird der Verbrauch des letzten Tages der separat erfassten ausgewählten Haushaltsgeräte sowie deren Betriebszeiten angezeigt. Wie bereits unter AP 3.2 erwähnt, wird der tatsächliche Gesamtverbrauch angezeigt, da die Disaggregationsalgorithmen nicht bei allen Geräten eine ausreichend hohe Genauigkeit erreichten, um den Bewohnern verlässliche Einzelwerte bereitzustellen. Stattdessen wurde als es als wichtiger erachtet, den Bewohnern möglichst genaue Informationen über die Nutzung dieser Geräte bereitzustellen, um ein bewussteres und gegebenenfalls effizienteres Verbrauchsverhalten zu fördern.

Zudem werden den Bewohnerinnen und Bewohnern verschiedene Energie- und Kostenspartipps vermittelt, die entweder allgemeingültig formuliert sind oder auf dem bisherigen Nutzungsverhalten spezifischer Haushaltsgeräte basieren. Die Entwicklung dieser Maßnahmen erfolgte unter Einbeziehung sozialwissenschaftlicher Kriterien, wie sie in den entsprechenden Arbeitspapieren der OTH dargelegt sind [1][12][13]. Im Anschluss wurden die Maßnahmen gemeinsam mit der OTH evaluiert. Aus dieser Evaluation wurden die Hinweise ausgewählt, die in besonderem Maße zur Erreichung der Projektziele beitragen.

Zentrale Auswahlkriterien waren dabei insbesondere das Potenzial zur Verhaltensänderung im Sinne einer Reduktion des Stromverbrauchs sowie die Minimierung möglicher Rebound-Effekte.

Darüber hinaus werden den Bewohnerinnen und Bewohnern Solarprognosen sowie wetterabhängige Handlungsempfehlungen bereitgestellt. Ziel ist es, Anreize zu schaffen, den Einsatz bestimmter Haushaltsgeräte zeitlich auf Phasen mit günstigerer Stromerzeugung – insbesondere durch Photovoltaik – zu verlagern. Es wurden drei Solar-Prognose-Tools betrachtet: der Fa. SMA, der Fa. EFR, und des Deutschen Wetterdienstes [14][15][17]. Diese wurden anschließend verglichen und bewertet. Abbildung 7 zeigt beispielhaft einen qualitativeren Vergleich der drei verschiedenen Prognosen mit der tatsächlichen PV-Erzeugung der PV-Anlage in Herzo Base für zwei aufeinanderfolgende Sommertage. Die Prognose des Deutschen Wetterdienstes hat die niedrigste mittlere quadratische Abweichung zu den echten Daten und ist daher am präzisesten. Deswegen wurde sie für die Darstellung der Wetterprognose in der Anwendung ausgewählt.




Abbildung 7: Tatsächliche PV- Erzeugung im Vergleich zu der prognostizierten Erzeugung von drei Solarprognose Tools.

AP 4 Rechtliche Bewertung des Designs, Definition von Anpassungen und Umsetzung

Die Technische Hochschule Nürnberg begleitete die rechtliche Bewertung des Projektdesigns durch den Projektpartner Universität Regensburg kontinuierlich und unterstützte diese mit allen erforderlichen Informationen. Insbesondere wurden bei Bedarf detaillierte Angaben zu Art, Umfang und Verlauf der Verarbeitung personenbezogener und haushaltsbezogener Daten innerhalb der entwickelten Systeme zur Verfügung gestellt.

Im Rahmen dieser Prüfung konnte festgestellt werden, dass die erfassten Daten durch geeignete technische und konzeptionelle Maßnahmen so anonymisiert bzw. aggregiert wurden, dass keine Rückschlüsse auf einzelne Personen möglich waren. Damit entspricht das bestehende Design den datenschutzrechtlichen Anforderungen, insbesondere im Hinblick auf die Vorgaben der Datenschutz-Grundverordnung (DS-GVO). Eine Anpassung der Systemarchitektur oder zusätzlicher technischer Maßnahmen war daher nicht notwendig.

AP 5 Erprobung der entwickelten Technologien/Algorithmen in der Pilotanwendung Herzo Base sowie Chancen, Risiken und Profiteure der entwickelten Technologien

Dieses Kapitel fasst die zentralen Ergebnisse des Arbeitspakets 5 zusammen. Die Technische Hochschule Nürnberg (THN) arbeitete über den gesamten Projektverlauf eng mit der Partnerhochschule OTH zusammen und stellte alle erforderlichen Daten zur Bearbeitung von AP 5.3 zur Verfügung. Das Kapitel fällt umfangreicher aus als Kapitel 1 und 3, da zu diesen Inhalten bislang kein Zwischenbericht vorliegt.

AP 5.1: Technische Umsetzung

Im Rahmen des AP 5.1 waren die kontinuierlich erfassten Messdaten aus dem im AP 3.1 installierten Messsystem in die von der Firma Proleit verwaltete Datenbank zu überführen. Aufgrund wiederholter Störungen des inzwischen sieben Jahre alten Serversystems von Proleit wurde jedoch beschlossen, die dort gespeicherten Daten in das neue Serversystem von EVEKT zu migrieren. Die Umsetzung dieser Aufgabe erfolgte erfolgreich durch die Firma Eniano. Die vom alten System erfassten Messwerte werden nun fortlaufend abgerufen und im EVEKT-Server gespeichert. Dadurch ist sichergestellt, dass die Arbeiten bei EVEKT unabhängig vom veralteten Serversystem und ohne potentielle Betriebseinschränkungen durchgeführt werden können. Das Messsystem für das Intensiv-Monitoring der Haushaltsgeräte wurde nach den unter AP 3.1 beschriebenen Verzögerungen in Februar 2025 in Betrieb genommen. Seitdem werden die Verbrauchsdaten der ausgewählten Haushaltsgeräte jede 1 min erfasst und gespeichert.

AP 5.2: Evaluation der entwickelten Systemkomponenten

Das entwickelte System wurde im Rahmen dieses Arbeitspaketes aus technischer, ökonomischer und ökologischer Perspektive evaluiert. Da die entwickelte Anwendung den teilnehmenden Haushalten aufgrund technischer Schwierigkeiten erst im März 2025 zur Verfügung gestellt werden konnte, lagen anfangs noch keine Daten über potentielle Nutzungsänderungen vor. Deshalb wurden für die wirtschaftliche und ökologische Evaluation zunächst Werte aus anderen thematisch verwandten Arbeiten genutzt. Hierfür wurden die vier Studien aus der Tabelle 1 in Betracht gezogen. Quellen [3] und [4] müssen dabei jedoch mit Vorsicht betrachtet werden, da hier die Einsparungen durch ein Feedback gekoppelt mit einem variablen Tarif entstanden sind. Dadurch können dabei nicht die gesamten erreichten Einsparungen auf das Stromverbrauchs-Feedback zurückgeführt werden.

Technische Evaluation des entwickelten Systems

Abbildung 8 zeigt schematisch das technische Setup der Mess- und Kommunikationsinfrastruktur der entwickelten Quartierslösung. Als Demonstrationsquartier zur Erprobung und Veranschaulichung der entwickelten Lösung diente der Reihenhauskomplex in Herzo

Base, bestehend aus drei teilnehmenden Haushalten. Ein Smart Meter in jedem Haushalt erfasst den gesamten Stromverbrauch in kWh mit einem Intervall von 15-min. Die Daten werden an den Server übermittelt, auf dem die Algorithmen laufen, welche von der Partnerfirma Eniano zur Verfügung gestellt werden. Mittels dieser Algorithmen werden die Rohdaten verarbeitet. Die aufbereiteten Daten und zusätzliche Informationen, welche aus den Daten gewonnen werden können, werden dem Haushalt über die Energiespar-Anwendung wieder zur Verfügung gestellt.

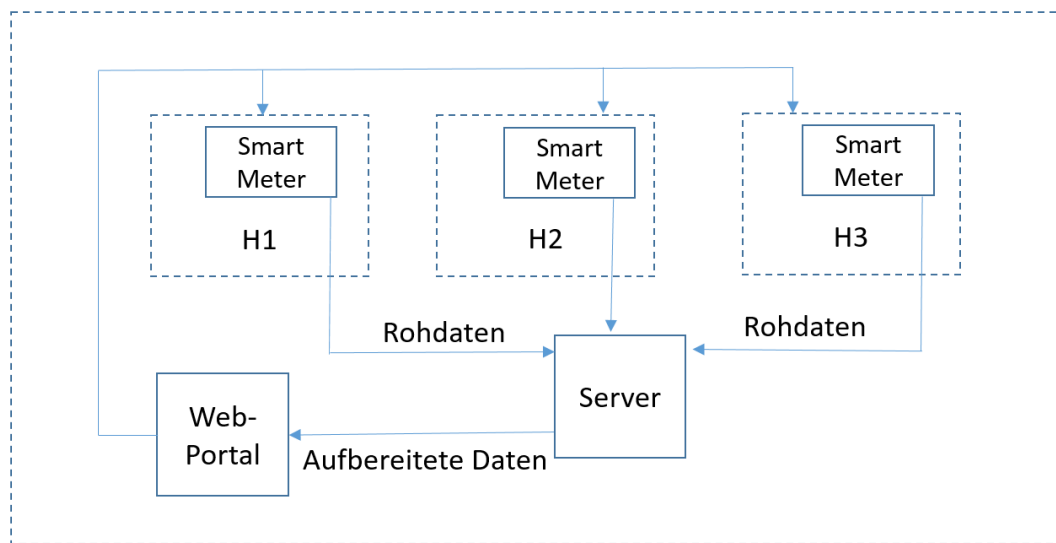


Abbildung 8: Technisches Setup der Mess- und Kommunikationsinfrastruktur in einem Quartier

Diese Systemkomponenten sind so konzipiert, dass sie mit minimalem Aufwand installiert, betrieben und gewartet werden können. Dadurch erfolgt eine unkomplizierte Inbetriebnahme sowie ein zuverlässiger, wartungsarmer Betrieb im Quartier. Dank der drahtlosen Datenübertragung mittels LoRaWAN-Technologie ist keine aufwendige Verkabelung erforderlich, was die Installation erheblich vereinfacht. Die Kommunikation erfolgt im Minutentakt mit einem geringen durchschnittlichen Datenverlust von etwa 3-4%, der die Funktionalität der Anwendung nicht beeinträchtigt. Die stabile Verbrauchsanzeige sowie die zuverlässige Verarbeitung der Daten durch die Serveralgorithmen gewährleisten eine hohe technische Stabilität im laufenden Betrieb. Es muss darauf hingewiesen werden, dass in einem realen Szenario der Server im Quartier eine größere Anzahl an Haushalten mit der Energiespar-Anwendung versorgt. Im realen Betrieb findet zudem keine Messung einzelner Geräte statt. Diese diente im Forschungsprojekt ausschließlich der Evaluation der eingesetzten Algorithmen. Die Smart-Meter-Daten werden nicht physisch per Kabel, sondern drahtlos an den Server übertragen. Die eingesetzte Hardware, die für eine Quartierlösung erforderlich ist, besteht aus Smart Metern und einem zentralen Server.

Bezüglich der Algorithmen wurde eine technische Bewertung bereits im Rahmen von Arbeitspaket 3.2 vorgenommen. Die Anzeige der Verbrauchsdaten erfolgt stabil und ohne technische Probleme. Der Algorithmus zur Berechnung der Grundlast wurde als besonders effizient eingestuft: Er erreicht eine hohe Genauigkeit bei gleichzeitig sehr geringem Rechenaufwand. Gleiches gilt für die Erkennung von Geräten mit konstantem oder periodischem Betrieb, wie etwa Kühlschränken. Im Gegensatz dazu ist die Identifikation von Geräten mit kürzeren und unregelmäßigen Nutzungszeiten, wie Waschmaschinen oder Geschirrspülern, weniger präzise. Dennoch konnten auch für diese Geräte tagesbasierte Flexibilitätspotenziale mit einer Genauigkeit von 60 – 80% ($E_{ACC} = 0.6 - 0.8$) ermittelt werden. Diese Informationen bieten einen zusätzlichen Mehrwert für die Nutzer, indem sie Hinweise auf mögliche Verschiebungen im Lastprofil liefern. Insgesamt zeigt die technische Evaluation, dass die entwickelte Systemarchitektur robust, skalierbar und für den angestrebten Praxiseinsatz geeignet ist.

Erzielbare Strom-, Kosten- und CO₂e-Einsparungen in den teilnehmenden Haushalten

Die potenziellen Stromeinsparungen der am EVEKT-Projekt beteiligten Haushalte wurden für vier Szenarien auf Basis der in Tabelle 1 dargestellten Studien in kWh pro Jahr berechnet. Grundlage der Berechnungen bildet der durchschnittliche Jahresstromverbrauch der teilnehmenden Haushalte in Herzo Base (vgl. Tabelle 12). Die resultierenden Einsparwerte sind in Tabelle 13 dargestellt.

Aus den möglichen Stromeinsparungen der teilnehmenden Haushalte in Herzo Base (Tabelle 13) lassen sich die finanziellen Einsparungen (Tabelle 14) berechnen. Der Stromarbeitspreis in den teilnehmenden Haushalten lag im Rahmen des Energieversorgungs-Vertrags mit BavariaStrom in 2024 bei 36,25 ct/kWh.

Tabelle 12: Jahresverbrauch in kWh/a der teilnehmenden Haushalte in Herzo Base für 6 Jahren

	2019	2020	2021	2022	2023	2024	Ø
H1	3626,1	3694,4	3865,9	3629,7	3355,7	3367,0	3589,8
H2	3983,8	4321,0	4860,9	4687,9	4282,5	4767,8	4484,0
H3	4793,0	5063,4	5192,4	5379,8	4715,3	4380,1	4921,0

Tabelle 13: Mögliche Stromeinsparungen der teilnehmenden Haushalte in Herzo Base [kWh/a]

	1%	3,70%	4,80%	13,90%
H2	35,9	132,8	172,3	499,0
H6	44,8	165,9	215,2	623,3
H8	49,2	182,1	236,2	684,0
Mittelwert	43,3	160,3	207,9	602,1

Tabelle 14: Mögliche Kosteneinsparungen der teilnehmenden Haushalte in Herzo Base [Euro/a]

	1%	3,70%	4,80%	13,90%
H2	13,0	48,1	62,5	180,9
H6	16,3	60,1	78,0	225,9
H8	17,8	66,0	85,6	247,9
Mittelwert	15,7	58,1	75,4	218,3

Die möglichen CO₂e-Einsparungen durch die Verwendung einer Energiesparanwendung in den beteiligten Haushalten wurden anhand der Emissionsfaktoren der Tabelle 6 ermittelt. In Herzo Base ist eine eigene PV-Anlage vorhanden. Tabelle 15 zeigt die berechnete potentielle CO₂e-Einsparungen der beteiligten Haushalte für die vier Szenarien der Tabelle 1, unter Berücksichtigung des anteilig genutzten, selbst erzeugten PV-Stroms. Ca. 65% des verbrauchten Stroms stammen aus der PV-Anlage. Die restlichen ca. 35% werden aus dem Netz bezogen.

Tabelle 15: Mögliche CO₂e-Einsparungen der teilnehmenden Haushalte für vier Einspar szenarien [kgCO₂e/a]

	1%	3,70%	4,80%	13,90%
H1	6,9	25,6	33,2	96,1
H2	8,6	31,9	41,4	120,0

H3	9,5	35,1	45,5	131,7
Mittelwert	8,3	30,9	40,0	115,9

Zudem wurden die mögliche CO_{2e}-Einsparungen auch für den Fall eines 100%-igen Netzbezugs berechnet. Wenn nur der deutsche Strommix aus Grundlage verwendet wird, so beträgt die Emission 445 Gramm CO_{2e} pro kWh Strom inkl. Vorketten für das Jahr 2023 [21]. In Tabelle 16 sind die möglichen CO_{2e}-Einsparungen der teilnehmenden Haushalte in Herzo Base auf Grundlage dieses Wertes dargestellt.

Tabelle 16: Mögliche CO_{2e}-Einsparungen der teilnehmenden Haushalte in Herzo Base anhand des deutschen Strommixes für vier Einsparszenarien [kgCO_{2e}/a]

	1%	3,70%	4,80% [3]	13,90%
H1	16,0	59,1	76,7	222,0
H2	20,0	73,8	95,8	277,4
H3	21,9	81,0	105,1	304,4
Mittelwert	19,3	71,3	92,5	267,9

Abschätzung der ökonomischen Tragfähigkeit der entwickelten Lösung-

Um die ökonomische Tragfähigkeit des entwickelten Systems abschätzen zu können, sollen die oben aufgezeigten potenziellen Kosten-Einsparungen dem Aufwand an Kosten für die Haushalte gegenübergestellt werden. Aus Gründen der Generalisierung wurden die möglichen Einsparungen anhand eines durchschnittlichen deutschen Haushalts mit einem Stromverbrauch von 3.383,3 kWh pro Jahr [22] berechnet. Die möglichen Stromeinsparungen eines durchschnittlichen deutschen Haushalts werden in die Tabelle 17 gezeigt.

Tabelle 17: Mögliche Stromeinsparungen in einem durchschnittlichen deutschen Haushalt für die vier Einsparszenarien [kWh/a]

	1%	3,70%	4,80%	13,90%
Stromeinsparungen [kWh/a]	33,83	125,18	162,40	470,28

Aus den Werten in Tabelle 17 lässt sich zusammen mit dem Wert des durchschnittlichen deutschen Strompreises die mögliche Kosteneinsparung eines durchschnittlichen deutschen Haushalts berechnen (Tabelle 18). Der durchschnittliche deutsche Stromtarif liegt im März 2025 bei 39,8 ct/kWh [23].

Tabelle 18: Mögliche Kosteneinsparungen für einen durchschnittlichen deutschen Haushalt für die vier Einsparszenarien [Euro/a]

	1%	3,70%	4,80%	13,90%
Kosteneinsparungen [Euro/a]	13,47	49,82	64,64	187,17

Die Bundesnetzagentur hat festgelegt, in welchem Umfang Haushalte durch die Einführung intelligenter Messsysteme finanziell belastet werden dürfen: Maximal sind einmalige Anschaffungskosten von bis zu 100 € sowie jährlich höchstens 40 € brutto für Einbau, Betrieb, Wartung, Ablesung und Datenübertragung zulässig [24]. Daraus und aus der Tabelle 18 wurde die Amortisationszeit eines Haushalts für jedes Einsparszenario ermittelt.

Tabelle 19: Amortisationszeit für einen durchschnittlichen deutschen Haushalt für die vier Einsparszenarien

	1%	3,70%	4,80%	13,90%
Amortisationszeit [a]	nie	11	5	<1

Für das Szenario mit den 1% Einsparungen wäre eine Amortisationszeit nie erreichbar, da die jährlichen Kosten höher sind, als die jährlichen Einsparungen. Dieses Szenario erweist sich daher in allen Fällen als wirtschaftlich nicht tragfähig, es sei denn, es wird eine Lösung entwickelt, in der die jährlichen Kosten niedriger als ~13 Euro/a sind.

Bewertung der ökologischen Tragfähigkeit der entwickelten Lösung

Die ökologische Tragfähigkeit des entwickelten Systems wird abgeschätzt, indem die potenziellen Einsparungen an Treibhausgasemissionen den für Herstellung und Betrieb der Systeme eingesetzten Energiemengen gegenübergestellt werden. Dabei wurde ebenfalls ermittelt, welche Quartiersgröße erforderlich wäre, damit die Lösung mindestens CO₂e-neutral betrieben werden kann.

Als Grundlage für die Berechnung wurde exemplarisch der CO₂e-Fußabdruck des im Projekt EVEKT in Herzo Base eingesetzten Servers herangezogen. Laut Herstellerangaben

beträgt dieser für Deutschland 2.410 ± 1.160 kg CO₂e (siehe PCF-Bericht von Dell, Anhang D). Zur Vereinfachung wurde im Folgenden der Mittelwert von 2.410 kg CO₂e angesetzt und auf die empfohlene Nutzungsdauer von vier Jahren verteilt, was einem jährlichen Ausstoß von 602,5 kg CO₂e entspricht. Basierend auf diesem Wert und die potenziellen CO₂e-Einsparungen eines durchschnittlichen Haushalts wurde die erforderliche Quartiersgröße berechnet, bei der eine negative CO₂e-Bilanz erreicht wird (Tabelle 20).

Tabelle 20: Anzahl an Haushalten im Quartier, welche nötig sind um eine negative CO₂e Bilanz zu erzielen

	1%	3,70%	4,80%	13,90%
Anzahl Haushalte	41	11	9	3

Es sei zudem angemerkt, dass alternative Nutzungsszenarien – wie etwa der Einsatz einer Cloud-Lösung, die eine große Anzahl von Haushalten zentral versorgen kann – potenziell zu einem deutlich geringeren CO₂e-Fußabdruck pro Haushalt führen können.

Betrachtung realer Einsparungen

Da die App erst verspätet zum Ende des Q1 2025 den Haushalten bereitgestellt werden konnte, wurde die Bewertung der tatsächlichen Einsparwerte und Verhaltensänderungen an den Schluss gestellt. Diese Bewertung erfolgte erst Ende Juli 2025, wobei die Energieverbrauchswerte bis zum 15. Juli 2025 betrachtet wurden.

Um die Effekte der App-Nutzung auf das Verhalten der Bewohner zu bewerten, wurden für alle drei Haushalte jeweils die Energiemengen der Grundlast und der mittleren Tageslast sowie die Nutzungszeiten der flexiblen Verbraucher für einen Zeitraum vor der App-Nutzung mit einem Zeitraum nach der Einführung der App verglichen. Es wird bei der Betrachtung mittlerer Tageslast sowie der Grundlast jeweils der Energieverbrauch während des Tages in Wh/Tag gemessen. Es wurden zwei Vergleichszeiträume gewählt.

Im ersten Fall wird der direkte Zeitraum vor der App-Nutzung 15.11.24 – 11.03.25 mit dem Zeitraum nach Einführung der App 11.03.25 – 15.07.25 verglichen. Dieser Zeitraum eignet sich besonders für den Vergleich der Energiemenge von Grundlast und mittlerer Tageslast. Die Gewohnheiten aber auch Rahmenbedingungen eines Haushaltes ändern sich ständig (z.B. Anzahl der Personen im Haushalt, Home-Office-Anteil, Art und Anzahl der el. Verbraucher...). Um den Einfluss dieser Effekte zu minimieren, ist es wichtig, einen Zeitraum zu wählen, der möglichst nah am Vergleichszeitraum liegt, da hier davon ausgegangen wird, dass die äußeren Rahmenbedingungen am ähnlichsten zu denen im Vergleichszeitraum sind.

Im zweiten Fall wird der Zeitraum 11.03.24 – 15.07.24 vor der App-Nutzung verglichen mit dem Zeitraum 11.03.25 – 15.07.25. Dieser Vergleichszeitraum eignet sich besonders zur Bewertung der Nutzungszeiten. Hierbei wird verglichen, wie hoch der zeitliche Anteil der Nutzung der flexiblen Geräte während den Sonnenstunden bzw. während der Tageszeit ist. Hierfür ist ein Vergleich mit einem Zeitraum zur gleichen Jahreszeit wichtig, da hier auch der Anteil der Sonnenstunden pro Tag vergleichbar ist.

Beim Vergleich der Energiemenge der Grundlast und der mittleren Tageslast werden vorher jeweils die Urlaubszeiten aus dem Datensatz entfernt, um einen Einfluss aufgrund von Anzahl der Urlaubstage zu verringern.


Tabelle 21 zeigt den Vergleich der Energiemenge der Grundlast und der mittleren Tageslast für die Zeiträume vor und nach der Einführung der App in den drei Test-Haushalten. Die mittlere Tageslast von H6 steigt im Vergleich zwischen dem gezeigten Zeitraum 15.11.24 – 11.03.25 und dem Zeitraum 11.03.25 – 15.07.25 (>16%), vielmehr aber noch zwischen dem Zeitraum 11.03.24 – 15.07.24 und dem Zeitraum 11.03.25 – 15.07.25 (>90%) unverhältnismäßig stark an. Um die Ursache genauer zu untersuchen, wurden die Tageslastprofile des betreffenden Haushalts betrachtet. Hierbei fällt auf, dass seit Beginn 2025 immer wieder eine größere Last von ca. 4,6 kW über mehrere Stunden betrieben wird, siehe auch Tabelle 22. Es wird davon ausgegangen, dass die Bewohner des Hauses sich zu Beginn 2025 ein E-Auto zugelegt haben.

Tabelle 21: Vergleich der Energiemenge der Grundlast und der mittleren Tageslast für die Zeiträume vor und nach Einführung der App in den drei Test-Haushalten

	Vor der App-Nutzung (15.11.24 – 11.03.25)	Nach der App-Nutzung (11.03.25 – 15.07.25)	Vergleich
H2	Energieverbrauch (Grundlast):	Energieverbrauch (Grundlast):	Veränderung Energieverbrauch (Grundlast):
	3941,46 Wh/Tag	3906,57 Wh/Tag	-8,93%
	Energieverbrauch (Mittlere Tageslast):	Energieverbrauch (Mittlere Tageslast):	Veränderung Energieverbrauch (Mittlere Tageslast):
	7449,33 Wh/Tag	7186,68 Wh/Tag	-3,53%
H6	Energieverbrauch (Grundlast):	Energieverbrauch (Grundlast):	Veränderung Energieverbrauch (Grundlast):

	: 3332,86 Wh/Tag	3012,48 Wh/Tag	-10,64%
Energieverbrauch (Mittlere Tageslast):	15164,58 Wh/Tag	Energieverbrauch (Mittlere Tageslast): 17606,37 Wh/Tag	Veränderung Energieverbrauch (Mittlere Tageslast): +16,10%
H8	Energieverbrauch (Grundlast):	Energieverbrauch (Grundlast):	Veränderung Energieverbrauch (Grundlast):
	4227,26 Wh/Tag	4041,93 Wh/Tag	-4,59%
Energieverbrauch (Mittlere Tageslast):	9029,12 Wh/Tag	Energieverbrauch (Mittlere Tageslast): 8318,48 Wh/Tag	Veränderung Energieverbrauch (Mittlere Tageslast): -7,87%

Tabelle 22: Beispielhafte Tageslastprofile H6 eines Tages vor der neuen Anschaffung (2024) und eines Tages nach der neuen Anschaffung (2025)



Um den Einfluss der Effekte der neuen Anschaffung zu minimieren, wurde somit bei H6 ein anderer Vergleichszeitraum gewählt. Der Vergleichszeitraum beginnt hierbei erst nach der Anschaffung des E-Autos zum 01.01.25. Die Ergebnisse in diesem Vergleichszeitraum sind in Tabelle 23 dargestellt.

Tabelle 23: Vergleich der Energiemenge der Grundlast und der mittleren Tageslast für die Zeiträume vor und nach Einführung der App in Haushalt 6

	Vor der App-Nutzung (01.01.25 – 11.03.25)	Nach der App-Nutzung (11.03.25 – 15.07.25)	Vergleich
H6	Energieverbrauch (Grundlast):	Energieverbrauch (Grundlast):	Veränderung Energieverbrauch (Grundlast):

	3241,82 Wh/Tag	3012,48 Wh/Tag	-7,61%
Energieverbrauch (Mittlere Tageslast):	Energieverbrauch (Mittlere Tageslast):	Veränderung Energieverbrauch (Mittlere Tageslast):	
	19572,57 Wh/Tag	17606,37 Wh/Tag	-10.05%

Hiermit wird gezeigt, dass in allen drei Haushalten nach Einführung der App der Energieverbrauch im Vergleich zu den Monaten von der Einführung der App gesenkt wurde.

Der Energieverbrauch der Grundlast wurde im Schnitt um $(8,93\%+7,61\%+4,59\%)/3 = 7,04\%$ gesenkt.

Der Energieverbrauch der mittleren Tageslast wurde im Schnitt um $(3,53\%+10,05\%+7,87\%)/3 = 7,15\%$ gesenkt.

Die hier gemessenen Einsparungen belaufen sich somit im oberen Bereich der vorher betrachteten möglichen Einsparungen. Die Spitzenlasten haben sich in den drei Haushalten durch die App-Nutzung nicht signifikant geändert.

Es wurde hiermit gezeigt, dass allein durch die Anzeige der Energieverbrauchsdaten und der Grundlast eine Einsparung um durchschnittlich über 7% zu erreichen ist. Hierfür sind keine zusätzlichen Komponenten erforderlich. Die Berechnung der Grundlast ist über einen einfachen Algorithmus mit sehr geringem Rechenaufwand realisierbar.

Betrachtung realer Lastverschiebungen

Zusätzlich wurde der Einfluss der App-Nutzung auf die Nutzung der flexiblen Verbraucher im Haushalt bewertet. Hierfür wurde berechnet, wie hoch der Anteil der Nutzung der flexiblen Verbraucher (Waschmaschine, Spülmaschine, Wäschetrockner) in den Sonnenstunden und außerhalb der Sonnenstunden ist. Da in der App eine Information über die Sonnenstunden pro Tag gegeben ist, soll hiermit untersucht werden, ob dies einen Einfluss auf die zeitliche Nutzung gewisser stromintensiver flexibler Verbraucher hat. Es wird zum einen untersucht, wie hoch die anteilige Nutzung während der Sonnenstunden ist, zum anderen, wie hoch die anteilige Nutzung während des Tages / der Nacht ist. Die Ergebnisse sind in Tabelle 24 dargestellt. Die Sonnenstunden werden hier definiert als die Zeit von Sonnenaufgang bis Sonnenuntergang. Der Tag beginnt laut Definition zwei Stunden nach dem Sonnenaufgang und endet zwei Stunden vor dem Sonnenuntergang

Tabelle 24: Nutzungszeiten energieintensiver flexibler Verbraucher vor und nach Einführung der App

	Vor der App-Nutzung (11.03.24 – 15.07.24)	Nach der App-Nutzung (11.03.25 – 15.07.25)	Bewertung
WM_H2	Gesamtverbrauch (kWh): 6917.00 kWh	Gesamtverbrauch (kWh): 6659.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden hat sich nach der Nutzung

	Anteil während Sonnenstunden: 26.82%	Anteil während Sonnenstunden: 44.42%	der App stark erhöht (um 66% während Sonnenstunden bzw. 49% während Tag)
	Anteil außerhalb Sonnenstunden: 73.18%	Anteil außerhalb Sonnenstunden: 55.58%	
	Anteil während dem Tag: 13.82%	Anteil während dem Tag: 20.54%	
	Anteil während Nacht: 86.18%	Anteil während Nacht: 79.46%	
GS_H2	Gesamtverbrauch (kWh): 45278.00 kWh	Gesamtverbrauch (kWh): 51753.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden hat sich nach der Nutzung der App ebenfalls erhöht (um 23% während Sonnenstunden bzw. 41% während Tag)
	Anteil während Sonnenstunden: 37.00%	Anteil während Sonnenstunden: 45.38%	
	Anteil außerhalb Sonnenstunden: 63.00%	Anteil außerhalb Sonnenstunden: 54.62%	
	Anteil während dem Tag: 26.25%	Anteil während dem Tag: 37.07%	
	Anteil während Nacht: 73.75%	Anteil während Nacht: 62.93%	
WM_H6	Gesamtverbrauch (kWh): 52448.00 kWh	Gesamtverbrauch (kWh): 90319.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden hat sich nach der Nutzung der App leicht erhöht (um 1% während Sonnenstunden bzw. 8% während Tag)
	Anteil während Sonnenstunden: 76.97%	Anteil während Sonnenstunden: 77.92%	
	Anteil außerhalb Sonnenstunden: 23.03%	Anteil außerhalb Sonnenstunden: 22.08%	
	Anteil während dem Tag: 58.80%	Anteil während dem Tag: 63.26%	
	Anteil während Nacht: 41.20%	Anteil während Nacht: 36.74%	
TRKN_H6	Gesamtverbrauch (kWh): 111040.00 kWh	Gesamtverbrauch (kWh): 94734.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden ist nach der Nutzung der App leicht gesunken (um 8% während Sonnenstunden bzw. 1% während Tag)
	Anteil während Sonnenstunden: 55.47%	Anteil während Sonnenstunden: 51.53%	
	Anteil außerhalb Sonnenstunden: 44.53%	Anteil außerhalb Sonnenstunden: 48.47%	
	Anteil während dem Tag: 39.28%	Anteil während dem Tag: 39.01%	
	Anteil während Nacht: 60.72%	Anteil während Nacht: 60.99%	

WM_H8	Gesamtverbrauch (kWh):	108817.00 kWh	Gesamtverbrauch (kWh):	85846.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden hat sich nach der Nutzung der App erhöht (um 10% während Sonnenstunden bzw. 22% während Tag)
	Anteil während Sonnenstunden:	63.93%	Anteil während Sonnenstunden:	70.42%	
	Anteil außerhalb Sonnenstunden:	36.07%	Anteil außerhalb Sonnenstunden:	29.58%	
	Anteil während dem Tag:	51.03%	Anteil während dem Tag:	62.34%	
	Anteil während Nacht:	48.97%	Anteil während Nacht:	37.66%	
GS_H8	Gesamtverbrauch (kWh):	112721.00 kWh	Gesamtverbrauch (kWh):	127508.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden ist nach der Nutzung der App gesunken (um 19% während Sonnenstunden bzw. 31% während Tag)
	Anteil während Sonnenstunden:	42.50%	Anteil während Sonnenstunden:	35.84%	
	Anteil außerhalb Sonnenstunden:	57.50%	Anteil außerhalb Sonnenstunden:	64.16%	
	Anteil während dem Tag:	32.75%	Anteil während dem Tag:	24.96%	
	Anteil während Nacht:	67.25%	Anteil während Nacht:	75.04%	
TRKN_H8	Gesamtverbrauch (kWh):	83283.00 kWh	Gesamtverbrauch (kWh):	54084.00 kWh	Anteil der Nutzung während des Tages / während der Sonnenstunden ist nach der Nutzung der App stark gesunken (um 52% während Sonnenstunden bzw. 86% während Tag)
	Anteil während Sonnenstunden:	61.23%	Anteil während Sonnenstunden:	40.18%	
	Anteil außerhalb Sonnenstunden:	38.77%	Anteil außerhalb Sonnenstunden:	59.82%	
	Anteil während dem Tag:	44.32%	Anteil während dem Tag:	23.85%	
	Anteil während Nacht:	55.68%	Anteil während Nacht:	76.15%	

In H2 wurden die flexiblen Verbraucher nach Einführung der App vermehrt in den Sonnenstunden bzw. während der Tageszeit genutzt (anteilige Erhöhung um 23 – 66%). In H6 ist keine signifikante Änderung der Nutzung der flexiblen Verbraucher erkennbar (Änderungen <10%). In H8 ist der anteilige Verbrauch in den Sonnenstunden tendenziell gesunken (um bis zu 86%). Hier kann man allerdings argumentieren, dass es sich hierbei um einen Trockner handelt und dieser vor allem außerhalb der Sonnenstunden benötigt wird.

Im Allgemeinen kann hier jedoch keine Verhaltensänderung hinsichtlich einer vermehrten Nutzung flexibler Verbraucher in den Sonnenstunden nachgewiesen werden. Während der Anteil in einem Haushalt anstieg, sank er in einem anderen Haushalt bzw. blieb in einem anderen Haushalt annähernd konstant.

Die Ergebnisse sind jedoch mit Vorsicht zu genießen, da es sich bei der PV-Anlage auf dem hier gezeigten Test-Gebäude um eine Gemeinschaftsanlage handelt und der direkte Nutzen einer Verhaltensänderung hinsichtlich einer vermehrten Nutzung des Stroms in den Sonnenstunden, für den einzelnen nicht direkt finanziell sichtbar wird. Es wird vermutet, dass ein stärkerer Anreiz gegeben ist in Haushalten, die eine eigene PV-Anlage besitzen und durch ihre Verhaltensänderung direkt finanziell entlohnt werden.

AP 5.4: Datenbasierte Mehrwertdienste für Stakeholder aus Wirtschaft, Kommunen und Politik

Neue datenbasierte Mehrwertdienste und Geschäftsmodelle

Mehrwertdienste

Durch die gewonnenen Daten können folgende datenbasierte Mehrwertdienste entwickelt werden:

- Energieeffizienz und Verbrauchsoptimierung

In diesem Bereich ist ein Echtzeit-Verbrauchsmonitoring möglich, bei dem der Energieverbrauch nahezu in Echtzeit über Apps oder Dashboards visualisiert wird. Zudem kann ein Vergleich mit ähnlichen Haushalten erfolgen, um Einsparpotenziale aufzuzeigen. Die Erkennung ineffizienter Geräte wird durch Mustererkennung unterstützt, wodurch sogenannte „Stromfresser“ im Haushalt identifiziert werden können. Ergänzend dazu erhalten Nutzer automatisierte, datengestützte Energiespartipps zur gezielten Reduktion ihres Verbrauchs.

- Dynamisches Lastmanagement

Hierzu gehören Vorschläge zur Lastverschiebung, bei denen empfohlen wird, energieintensive Geräte wie Waschmaschine oder Geschirrspüler zu Zeiten mit günstigeren oder umweltfreundlicheren Tarifen zu betreiben. Zusätzlich ist eine Automatisierung über Smart-Home-Systeme möglich, bei der Geräte wie Heizung, Warmwasserbereitung oder Ladestationen für E-Autos automatisch entsprechend des Strompreises oder der Netzlast gesteuert werden.

- Tarifoptimierung und Flexibilitätsdienste

Im Rahmen der Tarifoptimierung und Flexibilitätsdienste kann eine individuelle Tarifberatung erfolgen, bei der der Verbrauch analysiert wird, um passende Stromtarife – etwa zeitvariable Modelle – zu empfehlen. Darüber hinaus ist eine Teilnahme an Flexibilitätsmärkten möglich, bei der die Flexibilität vieler Haushalte gebündelt wird, um beispielsweise Regelleistung oder Netzdienste bereitzustellen.

- Netzdienste und Prognosen

Lastprognosen auf Haushaltsniveau unterstützen die Netzplanung oder den Netzbetrieb durch detaillierte Verbrauchsvorhersagen. Gleichzeitig können Netzengpässe frühzeitig erkannt werden, insbesondere auf kleineren Netzebenen, wo Lastspitzen kritisch sein können.

- Nachhaltigkeits- und Umweltservices

Im Sinne der Nachhaltigkeit und Umwelt bieten die Dienste die Möglichkeit, den CO₂-Fußabdruck in Echtzeit anzuzeigen – abhängig vom jeweils aktuellen Strommix. Zudem wird über sogenannte Grünstrom-Optimierungen informiert, also darüber, wann der Anteil erneuerbarer Energien im Netz besonders hoch ist, um gezielt zu diesen Zeiten Strom zu nutzen.

- Betrugserkennung und Sicherheit

Auch Sicherheit und Betrugserkennung lassen sich datenbasiert verbessern. Ungewöhnliche Verbrauchsmuster können als Frühwarnsignal dienen, etwa bei defekten Geräten oder unautorisiertem Zugriff. Ebenso kann die Simulation von Anwesenheit durch typisches Verbrauchsverhalten genutzt werden, etwa als Schutzmaßnahme während eines Urlaubs.

- Personalisierte Services und Gamification

Nicht zuletzt bieten die gewonnenen Daten Potenzial für personalisierte Services und Gamification. So lassen sich individuelle Nutzerprofile erstellen, auf deren Basis personalisierte Energie-Reports generiert werden. Durch spielerische Elemente wie Wettbewerbe mit Nachbarn oder Challenges zur Verbrauchsreduktion können zusätzliche Anreize geschaffen werden.

Teile der genannten Mehrwertdienste sind bereits in der im Rahmen des Forschungsprojekts entwickelten App implementiert.

Geschäftsmodelle

Aus den genannten Mehrwertdiensten lassen sich verschiedene Geschäftsmodelle entwickeln. Die Geschäftsmodelle inklusive der profitierenden Zielgruppen und einer Einschätzung zur Wirtschaftlichkeit sind in Tabelle 25 aufgelistet.

Tabelle 25: Geschäftsmodelle inklusive der profitierenden Zielgruppen und einer Einschätzung zur Wirtschaftlichkeit

Geschäftsmodell	Problem	Lösung	Zielgruppe	Gesellschaftlicher Mehrwert	Wirtschaftlichkeit
EnerCoach	<p>Privathaushalte wissen oft nicht, wann und wie sie Energie verbrauchen, wodurch Sparpotenziale ungenutzt bleiben. Dynamische Stromtarife, Lastspitzen und die Integration erneuerbarer Energien erfordern aktives Energiemanagement – doch die meisten Verbraucher haben keine Zeit oder das Wissen dafür.</p>	<p>EnerCoach ist eine App-gestützte Plattform, die auf viertelstündlichen Verbrauchsdaten basiert und automatisch Energiesparpotenziale erkennt, optimale Nutzungszeiten empfiehlt und auf Wunsch auch Verbrauchsgereäte steuert – für mehr Kon-</p>	<ul style="list-style-type: none"> • Privathaushalte mit Smart Meter / intelligentem Messsystem • Technikaffine Nutzer, die an Energieeffizienz, Nachhaltigkeit oder Kosteneinsparungen interessiert sind • Haushalte mit Photovoltaik, Batteriespeicher oder E-Autos (Premium-Segment) 	<ul style="list-style-type: none"> • Steuerung anhand dynamischer Preise: Die App kann auf Basis dynamischer Stromtarife (z. B. Börsenpreise) automatisierte Empfehlungen ausgeben oder Geräte aktiv steuern. So werden günstige Zeiten genutzt und Netze entlastet. • Nutzen zur Bestimmung dynamischer Preise (Prognosen anhand von Daten): Verbrauchsprofile aggregierter Haushalte könnten anonymisiert Energieversorgern zur 	<ul style="list-style-type: none"> • Vorteile: <ul style="list-style-type: none"> ○ Geringe Grenzkosten bei skalierbarer App. ○ Zahlungsbereitschaft bei technikaffinen Nutzern gegeben. ○ Partnerpotenzial (z. B. EVUs, Gerätehersteller). • Herausforderungen: <ul style="list-style-type: none"> ○ Wettbewerb mit kostenlosen oder durch Versorger gestützten Angeboten. ○ Behavioral Change schwer zu monetarisieren.

trolle, niedri-
gere Kosten
und mehr
Nachhaltigkeit.

Verfügung gestellt
werden, um zukünf-
tige Preisbewegungen
besser zu modellieren.

- Besserer Verbrauch
lokal erzeugter Ener-
gie: Durch Tipps zur
Nutzung von Strom
bei hoher PV-Einspei-
sung oder durch In-
tegration von lokalen
Erzeugungsdaten wird
der Eigenverbrauchs-
anteil lokal erhöht.

Erweiterungsvorschlag:

Kooperation mit Stadt-
werken oder Regional-
versorgern zur nutzer-
seitigen Flexibilisie-
rung von Tarifen (Tarif
mit Bonus bei netz-
dienlichem Verhalten).

- Fazit: Moderat wirt-
schaftlich, hohes Upsel-
ling-Potenzial bei Ge-
räte- oder Tarifvermark-
tung.
-

FlexiCollect

Mit dem steigenden Anteil erneuerbarer Energien (insbesondere Wind und Sonne) entstehen immer stärkere Schwankungen im Stromnetz. Es fehlt an kurzfristig verfügbaren Flexibilitäten, insbesondere im Niederspannungsbereich, um Netzstabilität zu gewährleisten. Gleichzeitig bleiben private Lastverschiebungspotenziale ungenutzt.

FlexiCollect ist eine Plattform, die auf Basis von viertelstündlichen Verbrauchsdaten und Geräteprofilen eine virtuelle Flexibilitätsplattform für private Haushalte schafft. Sie ermöglicht es, Lasten gezielt zu verschieben, aggregiert über viele Haushalte – und verkauft diese Flexibilität an Netzbetreiber, Energieversorger oder Flexibilitätsmärkte.

- Verteilnetzbetreiber, die Engpässe vermeiden oder lokale Lastspitzen managen wollen
- Energieversorger, die Portfolios flexibilisieren oder Redispatch-Kosten senken möchten
- Regionale Energiegemeinschaften, die lokale Flexibilität vermarkten wollen
- Privathaushalte mit Smart Metern und steuerbaren Geräten (z. B. Wärmepumpe, E-Auto)

- Ausbau von Ladeinfrastruktur: Durch koordinierte Lastverschiebung (z. B. E-Auto-Laden nachts) kann lokal mehr Ladeinfrastruktur ohne Netzausbau installiert werden.
- Netzbetreiber – Prognose für Netzausbau: Die Plattform liefert aggregierte Lastprognosen und Flexibilitätspotenziale auf Straßen- oder Stadtteilebene – als Input für Netzplaner.
- Dynamische Preise steuern / Prognosebasierte Nutzung: FlexiCollect kann gezielt Lasten in teure Preiszonen verschieben oder vermeiden –

- Vorteile:

- Teilnahme an Redispatch 2.0, Flexmärkten, Regelenergiemärkten = reale Erlöse.
- Netzbetreiber haben steigenden Bedarf an lokaler Flexibilität.
- Kombinierbar mit SmartCharge+ (E-Auto) und Wärmepumpen.

- Herausforderungen:

- Hohe technische und regulatorische Komplexität (Bilanzierung, Steuerbarkeit).
 - Noch geringe Flexibilitätsvergütung im Haushalt.
-

				<p>durch KI-basierte Prognosemodelle.</p> <p>Erweiterungsvorschlag:</p> <p>White-Label-Version für Netzbetreiber, die FlexiCollect als Werkzeug zur Engpassvermeidung im Verteilnetz einsetzen.</p>	<ul style="list-style-type: none"> • Fazit: Langfristig sehr wirtschaftlich, wenn regulatorisch etabliert. Relevantes B2B-Modell.
<p>HomeGuard Analytics</p>	<p>Viele Schäden im Haushalt (z. B. durch defekte Geräte, Brandrisiken oder Wasserboiler) kündigen sich durch veränderte Stromverbrauchsmuster an. Diese Risiken bleiben oft unerkannt, da es keinen intelligenten Monitoring-Dienst für Kleinschäden gibt. Versicherer zahlen Milliarden für</p>	<p>HomeGuard Analytics nutzt viertelstündliche Verbrauchsdaten, um abweichende Muster und potenzielle Gefahrenquellen in Echtzeit zu erkennen. Der Dienst benachrichtigt die Nutzer sofort und vermittelt</p>	<ul style="list-style-type: none"> • Privathaushalte, die Sicherheit und Komfort schätzen • Wohngebäudeversicherer, Hausratversicherer • Hausverwaltungen, Vermieter, Facility Management • Smart-Home-Nutzer, die ohnehin digital vernetzt sind 	<ul style="list-style-type: none"> • Netzbetreiber – Prognose für Netzausbau: Langfristige Verbrauchsanomalien können helfen, strukturelle Schwachstellen im Netzbetrieb zu identifizieren (z. B. permanente Überlastung durch neue Geräte im Haushalt). • Politik – Lokaler Verbrauch vs. Erzeugung: Frühwarnung bei 	<ul style="list-style-type: none"> • Vorteile: <ul style="list-style-type: none"> ○ Versicherungskooperationen ermöglichen B2B2C-Umsatz. ○ Wenig Wettbewerb im Segment „Haushalts-Risikoüberwachung“. • Herausforderungen: <ul style="list-style-type: none"> ○ Datenschutzerfordernungen und potenzielle Skepsis bei Haushalten.

vermeidbare Schäden, und Kunden fehlt die Früherkennung.

auf Wunsch Wartungsdienste – oder koppelt sich mit Versicherungen zur präventiven Schadensvermeidung.

Nichtnutzung lokal erzeugten Stroms (z. B. PV-Überschuss wird eingespeist, obwohl Geräte gleichzeitig laufen) hilft, Politikziele wie Eigenverbrauchsoptimierung umzusetzen.

- Monetarisierung hängt stark von Versicherern ab.
- Fazit: Nischensegment mit hoher Marge, v. a. für B2B-Kanäle interessant.

Erweiterungsvorschlag:

Partnerschaften mit Versicherern + Netzbetreibern, um Schäden und Netznutzungsanomalien gleichzeitig zu monitorieren.

EnerKlar

Energieverbrauch ist für viele – vor allem Kinder und Jugendliche – abstrakt, unsichtbar und unverständlich. In Schulen

EnerKlar ist eine digitale Lern- und Erlebnisplattform, die viertelstündliche

- Familienhaushalte mit schulpflichtigen Kindern (ca. 8–16 Jahre)
- Lehrkräfte und Schulen (v. a. Grundschule, Sek I)

- Politik – Bildung für lokales Energiemanagement: Das Modell eignet sich hervorragend, um politische Ziele wie Bürgerbil-

- Vorteile:
 - Unterstützt CSR-, Bildungs- und Kundenbindungsstrategien von Stadtwerken.
-

fehlt es oft an interaktiven Materialien zur Energie- und Klimabildung, obwohl das Thema hochrelevant für die Zukunft ist. Gleichzeitig suchen Eltern nach sinnvollen Möglichkeiten, ihre Kinder für Umwelt- und Alltagsbewusstsein zu sensibilisieren.

Verbrauchsdaten nutzt, um spielerisch und pädagogisch aufbereitete Inhalte zum Thema Energie, Nachhaltigkeit und Klimaschutz bereitzustellen. Haushalte oder Schulklassen erhalten Zugriff auf Dashboard, Lernmodule und Challenges, basierend auf ihrem realen Verbrauch.

- Bildungsinitiativen & Kommunen
- Energieversorger mit Bildungsauftrag oder regionalem Engagement

dung zur Energiewende zu unterstützen.

- Dynamische Preise verstehen: Kinder lernen über Challenges und Quizzes, wie Preise schwanken und wie man darauf reagiert – indirekt auch Elternbildung.

Erweiterungsvorschlag: Gamifizierte Schulprojekte zu "Wann ist Strom am günstigsten?" oder "Wir senken unsere Schulnetzlast!" mit Einbindung echter Preisdaten.

- Förderfähig (Klimabil- dung, schulische Bil- dung).

- Herausforderungen:

- Geringe direkte Zahlungsbereitschaft von Endkunden.
- Hohes didaktisches und inhaltliches Investment.

- Fazit: Geringe direkte Wirtschaftlichkeit, aber hochrelevant als Public-Value-Angebot.

Ener-Board

Die Wohnungs- und Immobilienwirtschaft steht unter wachsendem Druck,

EnerBoard ist eine Plattform, die viertel-

- Wohnungsgesellschaften, Genossenschaften, kommunale Wohnungsunternehmen

- Netzbetreiber – Prognose für Netzausbau: Durch granularen Datenzugriff auf große

- Vorteile:
-

<p>den Energieverbrauch zu senken, Transparenz herzustellen und ESG-Vorgaben (Environmental, Social, Governance) zu erfüllen. Gleichzeitig fehlt oft der Zugriff auf granulare Verbrauchsdaten, um Maßnahmen gezielt umzusetzen oder nachzuweisen.</p>	<p>stündliche Verbrauchsdaten aus Wohn- und Gewerbeeinheiten aggregiert, visualisiert und analysiert – zur automatisierten Berichterstattung, Verbrauchsoptimierung und ESG-Dokumentation. Die Plattform hilft Eigentümern und Verwaltern, energieeffizienter und regelkonform zu handeln.</p>	<ul style="list-style-type: none"> • Immobilienfonds & Asset Manager • Hausverwaltungen, Facility Manager • Projektentwickler im Neubau (Nachhaltigkeitszertifizierungen) 	<p>Immobilienbestände kann frühzeitig erkannt werden, wo durch Verdichtung oder neue Heizungs-systeme der Netzausbau nötig wird.</p> <ul style="list-style-type: none"> • Ausbau von Ladeinfrastruktur: Aggregierte Lademanagement-Daten aus MFH-Portfolios zeigen, wo trotz neuer E-Mobilität kein Netzausbau erforderlich ist. • Dynamische Preise steuern & nutzen: EnerBoard könnte Preisbewegungen vorhersagen und Optimierungen bei Heizstrom oder Wärmepumpenlaufzeiten empfehlen. 	<ul style="list-style-type: none"> ○ ESG-Druck zwingt Immobilienwirtschaft zum Monitoring. ○ Wiederkehrende SaaS-Erlöse mit hoher Zahlungsbereitschaft. ○ Synergien mit CAFM/ERP-Systemen (Cross-Selling). • Herausforderungen: <ul style="list-style-type: none"> ○ Integration in vorhandene Prozesse & Systeme erforderlich. • Fazit: Sehr wirtschaftlich, starkes B2B-SaaS-Modell mit regulatorischem Rückenwind.
--	--	--	---	--

EnergieNachbarn

Viele Haushalte mit Photovoltaikanlagen speisen Strom ungesteuert ins Netz, obwohl ihre Nachbarn ihn lieber direkt abnehmen würden – lokal, günstig und nachhaltig. Der Netzstrom ist teuer und enthält Abgaben, obwohl er technisch nur „um die Ecke“ fließt. Es fehlt ein System für direkte

EnergieNachbarn ist eine Plattform für Peer-to-Peer-Stromhandel in Nachbarschaften: Haushalte mit PV-Anlage können ihren selbst erzeugten Strom direkt an Nachbarn verkaufen. Die Plattform nutzt viertelstündliche Verbrauchs- und

- PV-Besitzer mit Überschussstrom
- Mieter oder Haushalte ohne eigene Erzeugung
- Energiegenossenschaften, Wohnprojekte, Quartiersentwicklungen
- Kommunen und Stadtwerke mit Interesse an Bürgerstrommodellen

Erweiterungsvorschlag:

Plattform-Addon für Netzverträglichkeitssimulation von Quartieren mit steigender E-Mobilität oder WP-Anteil.

- Politik – Lokale Nutzung vor Einspeisung: Der Peer-to-Peer-Ansatz erfüllt genau dieses Ziel – weniger Rückspeisung, mehr Nachbarschaftsnutzung.
- Dynamische Preise (lokal): Plattform kann je nach Einspeisung/Verbrauch lokal Preise anpassen (z. B. bei hoher PV-Erzeugung günstigerer Strom für Nachbarn).

- Vorteile:
 - Emotional aufladbares Geschäftsmodell ("Bürgerstrom").
 - Einnahmen aus Transaktionsgebühren, Plattformzugang, Abrechnung.
 - Herausforderungen:
 - Rechtsrahmen (Bilanzkreismanagement, Abgabenlast) ist noch nicht massenmarkttauglich.
-

ten, fairen Energieaustausch zwischen Haushalten.

Einspeisedaten, um automatisiert Stromflüsse, Abrechnungen und Vergütungen zu managen.

- Netzbetreiber – Prognosefähigkeit: Das Modell bietet Netzbetreibern Zugang zu hochauflösenden Einspeise-/Abnahme-Daten, um lokale Lastflüsse besser vorherzusagen.

- Aufwändige IT-Infrastruktur zur Abwicklung.

- Fazit: Zukunftsträchtig, aber heute noch begrenzt wirtschaftlich – Pilotregionen sinnvoll.

Erweiterungsvorschlag:

„Tarifkorridore“ oder dynamische Nachbarschaftspreise zur Flexibilisierung der lokalen Märkte.

Smart-Charge+

Ladevorgänge von E-Autos verursachen hohe Lastspitzen und unnötig hohe Stromkosten, wenn sie ungesteuert geschehen. Gleichzeitig bieten Elektroautos großes

SmartCharge+ ist eine intelligente Ladeplattform, die viertelstündliche Energieverbrauchsdaten mit Preisdaten, Netzstatus und

- Privathaushalte mit E-Auto und Smart Meter (Wallboxen oder mobile Ladeeinheit)
- Mehrfamilienhäuser mit gemeinsamer Ladeinfrastruktur

- Ausbau von Ladeinfrastruktur: Intelligentes Lademanagement erlaubt paralleles Laden vieler Fahrzeuge ohne Netzüberlastung.
- Dynamische Preise steuern & nutzen: E-

- Vorteile:

- E-Autos = hohes Lastverschiebungspotenzial = monetarisierbare Flexibilität.
 - Haushalte & Flotten bereit, für optimiertes
-

<p>Flexibilitätspotential, das bislang kaum genutzt wird – weder durch Privatnutzer noch durch Netzbetreiber oder Flottenmanager.</p>	<p>Fahrverhalten kombiniert, um optimale Ladezeiten zu berechnen. Sie steuert den Ladevorgang automatisch oder gibt konkrete Empfehlungen, sowohl für Haushalte mit eigenem E-Auto als auch für Flottenbetreiber.</p>	<ul style="list-style-type: none"> • Carsharing-Anbieter, Pflegedienste, Handwerksflotten • Stadtwerke & Netzbetreiber (für netzdienliches Laden) 	<p>Autos laden bevorzugt bei günstigen Preisen, was Nachfrage glättet. Dies ist wichtig für die Netzstabilität.</p>	<p>Laden zu zahlen (SaaS).</p>
			<ul style="list-style-type: none"> • Netzbetreiber – Prognosen für Netzausbau: Aggregierte Ladeprofile aus Wohnquartieren oder Flotten helfen bei der mittel- und langfristigen Netzausbauplanung. 	<ul style="list-style-type: none"> ○ Relevanz für Netzbetreiber (Netzstabilität).
			<p>Erweiterungsvorschlag: Bonusmodell für netzdienliches Laden in Kooperation mit Netzbetreibern, sichtbar im Nutzer-Dashboard.</p>	<ul style="list-style-type: none"> • Herausforderungen: <ul style="list-style-type: none"> ○ Heterogene Hardware (Wallboxen, Protokolle). ○ Kombination aus Energie-, Mobilitäts- und Netzdomäne. • Fazit: Sehr wirtschaftlich bei gezielter Zielgruppe, hohes Synergiepotenzial mit FlexiCollect.

Datenschutz

Die Ergebnisse der Umfrage (4. Arbeitspapier der OTH im Rahmen des Projekts EVEKT) der OTH Regensburg belegen, dass ein hoher Anteil der befragten Personen einen Zugriff auf ihre Energiedaten nur anonymisiert erlauben würde. Die Bereitschaft für einen Zugriff auf Energieverbrauchsdaten als personenbezogene Messwerte dagegen ist sehr niedrig. Fast allen teilnehmenden Personen ist dabei wichtig, dass sie selbst bestimmen können, wem sie Zugriff auf ihre Energieverbrauchsdaten erlauben, auch zeitweise (z.B. Energieberater). Abbildung 9 zeigt dabei, wie bereit die Befragten wären, ihre Energieverbrauchsdaten verschiedenen Personengruppen weiter zu geben. Die Umfragewerte sind in Tabelle 26 dargestellt.

Tabelle 26: Abstimmung der Befragten zum Thema Datenzugriff; Antwortmöglichkeiten: 1 = Ich wäre überhaupt nicht bereit. 2 = Ich wäre eher nicht dazu bereit. 3 = Ich bin unentschieden. 4 = Ich wäre bereit dazu. 5 = Ich wäre sehr bereit dazu

Zugriffsoptionen Energieverbrauchsdaten	N	M	SD	Median
(1) Ich würde den Zugriff auf meine Energieverbrauchsdaten als personenbezogene Messwerte erlauben, so dass ein Rückschluss auf meinen Namen und meine Adresse möglich ist.	2020	1,77	1,025	1,00
(2) Ich würde den Zugriff auf meine Energieverbrauchsdaten nur anonym erlauben, also ohne Bezug zu meinem Namen und meiner Adresse.	2012	3,42	1,245	4,00
(3) Ich kann mir aus datenschutzrechtlichen Gründen nicht vorstellen, Zugriff auf meine Energieverbrauchsdaten zu erlauben.	2007	3,33	1,183	3,00
(4) Ich möchte selbst entscheiden können, wem ich den Zugriff auf meine Energieverbrauchsdaten erlaube, auch zeitweise (z.B. einem Energieberater).	2018	4,26	0,828	4,00
(5) Für einen günstigeren Stromtarif erlaube ich den Zugriff auf meinen Energieverbrauch.	2012	2,69	1,219	3,00
(6) Für eine jährliche Bonuszahlung erlaube ich den Zugriff auf meinen Energieverbrauch.	2027	2,58	1,278	3,00
(7) Für konkrete Stromsparhinweise erlaube ich den Zugriff auf meinen Energieverbrauch.	2019	2,51	1,254	2,00

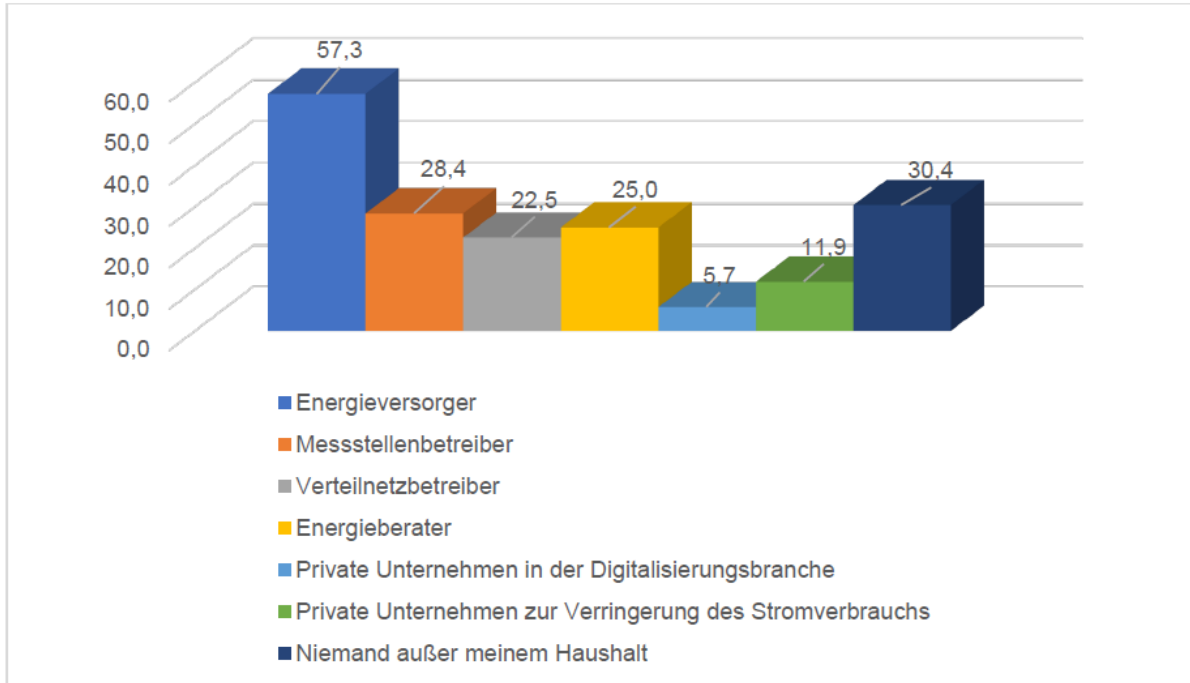


Abbildung 9: Zustimmung zum Zugriff auf Energieverbrauchsdaten; Anmerkung: in Prozent

Somit kommt zum Thema Weitergabe von Energieverbrauchsdaten ausschließlich die Möglichkeit eines Opt-ins in Frage, wobei die Nutzer selbst entscheiden können ob und mit wem sie ihre Energieverbrauchsdaten teilen.

Die strukturierte Auswertung und Nutzung von App-Daten bietet signifikante strategische Vorteile – vorausgesetzt, sie erfolgt DSGVO-konform und mit explizitem Opt-in der Nutzer. Auf dieser Grundlage lässt sich ein nachhaltiges Modell zur Datenlizenzierung etablieren, bei dem anonymisierte oder aggregierte Informationen interessierten Dritten – z. B. aus der Energie- oder Smart-Home-Branche – zur Verfügung gestellt werden können.

Im Rahmen freiwilliger und DSGVO-konformer Opt-in-Prozesse können Nutzer anonymisierte Gerätedaten für Forschungseinrichtungen, Hersteller oder Energieversorger zur Verfügung stellen. Die App fungiert hier als Vermittlerin und erhält entweder eine Provision oder eine Nutzungsgebühr pro weitergegebenem Datensatz. Nutzer wiederum profitieren finanziell – z. B. durch direkte Vergütung oder indirekt über Rabatte und exklusive Angebote.

Wirtschaftlichkeitsbetrachtung

Grundlage für viele datenbasierte Geschäftsmodelle ist eine funktionierende Smart-Meter-Infrastruktur. Smart Meter ermöglichen viertelstundengenaue Verbrauchsdaten, die neue Geschäftsmodelle überhaupt erst möglich machen – etwa zur Erfüllung gesetzlicher Vorgaben wie dem MsbG, Redispatch 2.0 oder der EED (Energy Efficiency Directive / Energieeffizienzrichtlinie der EU). Die Installationskosten sind derzeit noch hoch, insbesondere bei intelligenten Messsystemen (iMsys), während der flächendeckende Rollout nur langsam vorschreitet. Jährliche Gebühren von max. 40 € pro Haushalt begrenzen zudem die Erlösmöglichkeiten. Damit sind Smart Meter zwar (noch) keine direkte Einnahmequelle, aber eine notwendige Enabler-Technologie.

Die Einführung eines Smart Meters stellt für Verbraucher und Anbieter zunächst eine Investition dar. Damit sich diese Investition langfristig lohnt, muss sie durch nachweisbare Einsparungen oder zusätzliche Einnahmequellen kompensiert werden. Genau hier setzen die Apps sowie die genannten Mehrwertdienste und Geschäftsmodelle an. Somit unterstützen mögliche Geschäftsmodelle bei der transparenten Darstellung der Wirtschaftlichkeit eines Smart-Meter-Einsatzes. Sie bieten eine strukturierte Übersicht der relevanten Faktoren:

- Kosten: Anschaffung, Installation und Wartung des Smart Meters
- Ersparnisse: Reduzierter Energieverbrauch durch verbesserte Verbrauchstransparenz, Verhaltensanpassungen und optimierten Geräteeinsatz
- Mehrwerte: Automatisierte Verbrauchsanalysen, Warnungen bei ungewöhnlichen Lastspitzen sowie individuelle, datenbasierte Energiespartipps

Auf Basis der gesammelten Verbrauchsdaten kann eine konkrete Aussage zur Wirtschaftlichkeit getroffen werden. Beispiel: „Durch die Nutzung eines Smart Meters sparst du aktuell rund 80 € pro Jahr. Bei Investitionskosten von 240 € amortisiert sich dein Gerät in etwa drei Jahren.“

So wird der finanzielle Nutzen für Endkunden greifbar – eine wichtige Voraussetzung, um Akzeptanz zu schaffen und den Rollout intelligenter Messsysteme aktiv zu fördern.

2.2 Verwendung der Zuwendung

Die Verwendung der Zuwendung ist im nicht öffentlichen Erfolgskontrollbericht des jeweiligen Projektpartners dokumentiert.

2.3 Verwertungsplan

Lfd. Nr.	Bezeichnung	Zeithorizont
1	Verwertung der gesammelten Daten und Ergebnisse in Lehrveranstaltungen	Ab sofort
2	Verwertung der gesammelten Daten und Ergebnisse in weiteren Forschungsvorhaben im Bereich der el. Netze zur Integration erneuerbarer Energien und Speichertechnologien, Sektorkopplung	Ab sofort
3	Vorstellung der Ergebnisse in Fachgremien	Ab sofort
4	Einreichung der Ergebnisse zur Publikation	Ab sofort

2.4 Stand der Technik während der Projektlaufzeit

Ein bedeutender regulatorischer Impuls zur Weiterentwicklung der technischen Rahmenbedingungen wurde durch das im Mai 2023 in Kraft getretene „Gesetz zum Neustart der Digitalisierung der Energiewende“ gesetzt. Die vollständige Gesetzesfassung ist im Bundesgesetzblatt Teil I Nr. 133 vom 26. Mai 2023 veröffentlicht. Dieses Gesetz zielt darauf ab, den schleppenden Rollout intelligenter Messsysteme (Smart Meter) deutlich zu beschleunigen und schafft damit neue Voraussetzungen für datenbasierte Anwendungen im Energiebereich. Im Rahmen des Gesetzes wurde ein verbindlicher Rollout-Fahrplan eingeführt, der vorsieht, dass Haushalte mit einem Jahresstromverbrauch von über 6.000 kWh sowie Betreiber von Photovoltaikanlagen ab 7 kWp schrittweise bis spätestens 2030 mit Smart Metern ausgestattet werden. Für größere Verbraucher und Erzeuger gelten noch ambitioniertere Fris-

ten. Ergänzend dazu verpflichtet das Gesetz Stromanbieter ab 2025 zur Einführung dynamischer Stromtarife, wodurch eine flexible und verbrauchsnahe Energienutzung gestärkt werden soll.

Diese gesetzlichen Neuregelungen verbessern nicht nur die technische Infrastruktur im Energiesektor, sondern schaffen zugleich eine deutlich erweiterte Anwendungsbasis für die im vorliegenden Projekt entwickelten Komponenten. Die standardisierte Ausstattung mit Smart Metern, kombiniert mit einem rechtlichen Rahmen, der Transparenz, Sicherheit und Verbraucherfreundlichkeit gewährleistet, trägt wesentlich zur Skalierbarkeit und Zukunftsfähigkeit entsprechender digitaler Energiemanagementsysteme bei. Die Projektergebnisse können somit auf eine zunehmend flächendeckende, interoperable Infrastruktur aufbauen, die während der Projektlaufzeit noch nicht vollständig gegeben war.

Im Zeitraum von 2022 bis 2025 konnten im Rahmen erster Modellprojekte, regionaler Pilotvorhaben und wissenschaftlicher Begleitstudien sowohl signifikante Einspar- als auch Flexibilisierungspotenziale identifiziert und teilweise realisiert werden. Die Studie von [28] untersucht, wie systematische Verbrauchsdaten – etwa durch Smart Meter – dabei helfen können, Energieeinsparpotenziale im Gebäudesektor zu identifizieren. Sie zeigt, dass durch genauere Erfassung von Strom- und Heizungsverbräuchen Optimierungspotenziale sichtbar werden. Zugleich wird der zusätzliche Stromverbrauch durch die digitale Messtechnik selbst bewertet, um die Nettoeinsparungen korrekt einordnen zu können.

Es wurden in [29] Haushalte mit Wärmepumpen untersucht, wobei die Smart-Meter-Daten dazu genutzt wurden, die Haushalte zu ermitteln, die ein hohes Einspar- und Optimierungspotential zeigten. Basierend auf historischen Smart-Meter-Verbrauchsprofilen wurden bestimmte Kennwerte ausgewählt – etwa besonders hoher oder ineffizienter Stromverbrauch der Wärmepumpe. Durch professionelle Pumpen-Inspektionen und Nutzertrainings wurden Einsparungen von 15.2% erreicht.

In Haushalten mit einem Verbrauch von 6.000 kWh ergibt sich durch die Einsparungen, welche aufgrund eines Smart-Meters möglich sind, ein jährlicher Kostenvorteil von etwa 80 €/a. [30]

Gleichzeitig zeigte sich ein wachsendes Flexibilisierungspotenzial durch den zunehmenden Einsatz steuerbarer Verbraucher (wie Wärmepumpen, Ladeinfrastruktur für E-Fahrzeuge und Batteriespeicher). Durch zeitvariable Tarife und Preissignale – dort, wo sie bereits eingeführt wurden – konnten Lastverschiebungen in Tagesrandzeiten erfolgreich getestet wer-

den. Diese Flexibilität wurde insbesondere im Kontext der Netzstabilisierung und der Integration volatiler erneuerbarer Energien als entscheidend eingestuft. Bei dynamischen Stromtarifen werden durch flexibles Laden von Elektroautos mögliche Stromkosteneinsparungen von über 68% gegenüber dem sofortigen Laden genannt. [31] In Deutschland trägt eine flexible Stromnachfrage maßgeblich zur Entlastung des Energiesystems bei: Sie halbiert sowohl die residuale Spitzenlast als auch die residuale Gesamtnachfrage und verringert die Überschusserzeugung um 80 %. Den größten Beitrag leistet dabei der flexible Betrieb von Elektrolyseuren – er ist für 42 % der Reduktion der residualen Spitzenlast und 59 % der verringerten residualen Nachfrage verantwortlich. [32]

Die gewonnenen Erfahrungen und technischen Rückkopplungen aus diesem Zeitraum fließen direkt in die Weiterentwicklung digitaler Energiemanagementsysteme ein. Sie belegen die Relevanz eines umfassenden Rollouts intelligenter Messsysteme nicht nur zur Verbrauchstransparenz, sondern auch als zentrales Instrument zur sektorübergreifenden Steuerung, insbesondere im Zusammenspiel von Strom, Wärme und Mobilität.

3 Zusammenfassung

Es wurde eine Webanwendung entwickelt, welche den Nutzer allein durch Anzeige seiner Energieverbrauchsdaten zu Einsparungen bewegte. In der App wurden der Stromverbrauch, die Grundlast, der CO₂e-Score, sowie Solarprognosen und Handlungsempfehlungen angezeigt. Die Grundlast konnte mittels eines einfachen Algorithmus berechnet werden. Die Transparenz des Energieverbrauchs durch die Nutzung der App hat zu realen Einsparungen des Energieverbrauchs von Grundlast sowie von der mittleren Tageslast durchschnittlich im Bereich von 7% geführt bei gleichbleibenden Spitzenlasten.

Es wurde somit gezeigt, dass allein durch die Bereitstellung von Informationen über den Stromverbrauch und die Grundlast die Nutzer für ihr Energieverbrauchsverhalten sensibilisiert und somit zu Einsparungen bewegt werden konnten. Benötigt wurden hierfür lediglich Smart-Meter-Daten in 15-minütiger Auslösung, wie sie in Zukunft durch den Smart-Meter-Rollout sowieso zur Verfügung stehen werden.

Es wurden drei KI-Algorithmen zur Dissaggregation verschiedener Haushaltsverbraucher getestet. Hierbei wurden bei den nicht-flexiblen Lasten wie der Grundlast sowie Kühl- und Gefriergeräten sehr gute Ergebnisse erzielt. Flexible Verbraucher wie z.B. Wasch- und Spülmaschinen konnten mit Hilfe der Algorithmen nicht zuverlässig erkannt werden. Durch die kombinierte Betrachtung mehrerer flexibler Geräte konnte die Genauigkeit der Erkennung jedoch gesteigert werden.

Eine Verschiebung der Nutzungszeiten flexibler Verbraucher in sonnenreiche Stunden kann nicht mit Sicherheit festgestellt werden. Als Grund hierfür wurde vermutet, dass es sich bei dem Test-Gebäude um eine Gemeinschafts-PV-Anlage handelt und finanzielle Erlöse durch die direkte PV-Strom-Nutzung nicht direkt beim Nutzer ankommen. Es wird vermutet, dass der Anreiz zur Verschiebung flexibler Lasten bei einer eigenen PV-Anlage höher ist.

Die hierbei gewonnenen Daten bringen gesellschaftlichen Mehrwert. Anhand datenbasierter Mehrwertdienste wurden verschiedene Geschäftsmodelle entwickelt, um das Potential zu zeigen.

4 Veröffentlichungen, Poster und Vorträge

Konferenzbeiträge

K. Koutrouveli, I. Mladenovic, C. Dettelbacher, O. Elattar, “Motivating households to adopt climate-friendly behavior by using smart meter data and AI technologies”, Clima 2025, Mailand, 2025

K. Koutrouveli, I. Mladenovic, C. Dettelbacher, O. Elattar, “Methodology for the estimation of the flexibilization potential of household consumers in electrical grids”, ETG-Kongress, Kassel, 2025

Poster

K. Koutrouveli, I. Mladenovic, C. Dettelbacher, O. Elattar, “Motivating households to adopt climate-friendly behavior by using smart meter data and AI technologies”, Clima 2025, Mailand, 2025

K. Koutrouveli, I. Mladenovic, C. Dettelbacher, O. Elattar, “Methodology for the estimation of the flexibilization potential of household consumers in electrical grids”, ETG-Kongress, Kassel, 2025

5 Anhang

- A) KI- und Automatisierungs-Szenarien sowie ihr Einfluss auf CO₂e- / Strom- und Kosteneinsparungen
- B) K. Koutrouveli, I. Mladenovic, C. Dettelbacher, O. Elattar, “Motivating households to adopt climate-friendly behavior by using smart meter data and AI technologies”, Clima 2025, Mailand, 2025
- C) K. Koutrouveli, I. Mladenovic, C. Dettelbacher, O. Elattar, “Methodology for the estimation of the flexibilization potential of household consumers in electrical grids”, ETG-Kongress, Kassel, 2025
- D) PCF-Report der Firma Dell für den Server Poweredge R350

6 Literatur

- [1] A. Aretz, N. Ouanes, H. Stange, C. Lenk, R. Holzner und L. Brischke, "Evaluation of the energy saving potential through systematic data collection of the electricity consumption and heating system operation in the building sector," *ECEEE Summer Study Proceedings*, S. 1165–1177, 2022.
- [2] J. Schleich, M. Klobasa, S. Gözl und M. Brunner, "Effects of feedback on residential electricity demand: Findings from a field trial in Austria," *Energy Policy*, Bd. 61(C), S. 1097–1106, 2013.
- [3] S. Seebauer et al, „€CO2-Management Sub 3 Sozioökonomische Begleitforschung“, Synthesebericht, im Auftrag von Klima und Energiefonds des Bundes, Programm *Neue Energien 2020*, Graz/Wien, 2013.
- [4] C. Meinecke, *Potentiale und Grenzen von Smart Metering: Empirische Wirkungsanalyse eines Feldtests mit privaten Haushalten*. Wiesbaden: Springer Fachmedien, 2017.
- [5] B. Zhao, L. Stankovic und V. Stankovic, "Electricity usage profile disaggregation of hourly smart meter data," Posterpräsentation, *4th International Workshop on Non-Intrusive Load Monitoring*, Austin, USA, 2018.
- [6] K. Basu, V. Debusschere, S. Bacha, U. Maulik und S. Bondyopadhyay, "Nonintrusive Load Monitoring: A Temporal Multilabel Classification Approach," *IEEE Transactions on Industrial Informatics*, Bd. 11, Nr. 1, S. 262–270, 2015, doi: 10.1109/TII.2014.2361288.
- [7] L. Massidda, M. Marrocu und S. Manca, "Non-intrusive load disaggregation by convolutional neural network and multilabel classification," *Applied Sciences*, Bd. 10, Nr. 4, Art. 1454, 2020, doi: 10.3390/app10041454.
- [8] B. Zhao, M. Ye, L. Stankovic und V. Stankovic, "Non-intrusive load disaggregation solutions for very low-rate smart meter data", *Applied Energy*, Bd. 268, 2020, doi: 10.1016/j.apenergy.2020.114949.
- [9] C. Zhang, M. Zhong, Z. Wang, N. Goddard und C. Sutton, "Sequence-to-point learning with neural networks for nonintrusive load monitoring", in *Proc. 32nd AAAI Conf. Artificial Intelligence (AAAI-18)*, 2018.
- [10] B. Zhao, L. Stankovic und V. Stankovic, "On a Training-Less Solution for Non-Intrusive Appliance Load Monitoring Using Graph Signal Processing," *IEEE Access*, Bd. 4, S. 1784–1799, 2016, doi: 10.1109/ACCESS.2016.255746.
- [11] M. Kaselimi, A. Voulodimos, E. Protopapadakis, N. Doulamis und A. Doulamis, "EnerGAN: A generative adversarial network for energy disaggregation," in *ICASSP 2020 - IEEE Int.*

- Conf. Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, Spanien, 2020, S. 1578-1582, doi: 10.1109/ICASSP40776.2020.9054342.
- [12] A. Majumdar, "Trainingless Energy Disaggregation Without Plug-Level Sensing," *IEEE Transactions on Instrumentation and Measurement*, Bd. 71, Art. 2504808, S. 1-8, 2022, doi: 10.1109/TIM.2022.3152311.
- [13] S. Singh und A. Majumdar, "Analysis Co-Sparse Coding for Energy Disaggregation," *IEEE Transactions on Smart Grid*, Bd. 10, Nr. 1, S. 462-470, 2019, doi: 10.1109/TSG.2017.2743763.
- [14] Sunny Portal, *Online-Überwachungssystem für die PV-Anlage auf der Herzo Base*, Online-Zugriff, 2025.
- [15] EFR GmbH, *Bereitstellung einer Solarprognose über den vorhandenen Server auf der Herzo Base*, Projektinterne Quelle, 2025.
- [16] T. Lauf, M. Memmler und T. Schneider, „Emissionsbilanz Erneuerbarer Energieträger 2021,“ Umweltbundesamt, 2022. [Online]. Verfügbar: https://www.umweltbundesamt.de/sites/default/files/medien/11850/publikationen/20231219_49_2023_cc_emissionsbilanz_erneuerbarer_energien_2022_bf.pdf [Zugriff am: 26. August 2025].
- [17] K. Knoll, *DWDForecast – GitHub Repository*, [Online]. Verfügbar: <https://github.com/kilianknoll/DWDForecast> [Zugriff am: 25. Juni 2025].
- [18] A. Miyasawa, Y. Fujimoto und Y. Hayashi, "Energy Disaggregation Based on Smart Metering Data via Semi-Binary Nonnegative Matrix Factorization" *Energy and Buildings*, Bd. 183, 2018, doi: 10.1016/j.enbuild.2018.10.030.
- [19] Germanwatch e.V., *Künstliche Intelligenz für die Energiewende – Chancen und Risiken*, Hintergrundpapier, Apr. 2021. [Online]. Verfügbar: <https://www.germanwatch.org/sites/default/files/K%C3%BCnstliche%20Intelligenz%20f%C3%BCr%20die%20Energiewende%20-%20Chancen%20und%20Risiken.pdf> [Zugriff am: 26. August 2025].
- [20] J. Edmonds und Z. S. Abdallah, „IMG-NILM: A Deep learning NILM approach using energy heatmaps,“ in *Proc. 38th ACM/SIGAPP Symp. Applied Computing*, New York: ACM, 2023, S. 1151-1153.
- [21] P. Icha und T. Lauf, „Entwicklung der Spezifischen Treibhausgas-Emissionen des deutschen Strommix in den Jahren 1990 – 2023“, Umweltbundesamt, 2024. [Online]. Verfügbar: <https://www.umweltbundesamt.de/publikationen/entwicklung-der-spezifischen-treibhausgas-10> [Zugriff am: 27 Mai 2025].

- [22] Statista, “Stromverbrauch eines Privathaushalts in Deutschland,” [Online]. Verfügbar: <https://de.statista.com/statistik/daten/studie/245790/umfrage/stromverbrauch-eines-privathaushalts-in-deutschland/> [Zugriff am: 25. Juni 2025].
- [23] Bundesverband der Energie- und Wasserwirtschaft (BDEW), “Strompreisanalyse,” [Online]. Verfügbar: <https://www.bdew.de/service/daten-und-grafiken/bdew-strompreisanalyse/> [Zugriff: März 2025].
- [24] Bundesnetzagentur, “Intelligentes Messsystem – Informationen für Verbraucher,” [Online]. Verfügbar: https://www.bundesnetzagentur.de/DE/Vportal/Energie/Metering/Flyer_iMSys.pdf [Zugriff am: 25. Juni 2025].
- [25] Bitkom, „Erfolgsfaktoren für einen zügigen Smart Meter Rollout“, [Online]. Verfügbar: <https://www.bitkom.org/Bitkom/Publikationen/Erfolgsfaktoren-fuer-einen-zuegigen-Smart-Meter-Rollout> [Zugriff am: 14. Juli 2025].
- [26] Bundesnetzagentur, *Monitoringbericht 2022*, [Online]. Verfügbar: <https://data.bundesnetzagentur.de/Bundesnetzagentur/SharedDocs/Mediathek/Monitoringberichte/MonitoringberichtEnergie2022.pdf> [Zugriff am: 14. Juli 2025].
- [27] Solarenergie.de, “Kosten für Smart Meter: Lohnt es sich?” [Online]. Verfügbar: <https://www.solarenergie.de/smart-home/smart-meter/kosten> [Zugriff am: 14. Juli 2025].
- [28] A. Aretz et al., „Evaluation of the energy saving potential through systematic data collection of the electricity consumption and heating system operation in the building sector“, *ECEEE Summer Study Proceedings*, S. 1165 – 1177, 2022.
- [29] A. Weigert, K. Hopf, S. A. Günther und T. Staake, “Heat pump inspections result in large energy savings when a pre-selection of households is performed: A promising use case of smart meter data”, *Energy Policy*, Bd. 169, 2022, <https://doi.org/10.1016/j.enpol.2022.113156>.
- [30] BDEW, “Smart Metering: Was Sie über intelligente Messsysteme wissen sollten,” [Online]. Verfügbar: <https://www.bdew.de/energie/digitalisierung/welche-rolle-spielen-smart-meter-fuer-die-digitalisierung-der-energiewende> [Zugriff am 16.07.2025].
- [31] C. Lohr, A. Eicke und L. Hirth, “Kurzstudie: Intelligentes Laden,” [Online]. Verfügbar: <https://neon.energy/Neon-Intelligentes-Laden.pdf> [Zugriff am 25.02.2025].
- [32] L. Göke, J. Weibezahn und M. Kendzioriski, “How flexible electrification can integrate fluctuating renewables,” *Energy*, Bd. 278, 2023, <https://doi.org/10.1016/j.energy.2023.127832>.

- [33] K. Koutrouveli, I. Mladenovic, C. Dettelbacher und O. Elattar, “Motivating households to adopt climate-friendly behavior by using smart meter data and AI technologies,” *RE-HVA HVAC World Congress CLIMA*, Mailand, 2025.
- [34] K. Koutrouveli, I. Mladenovic, C. Dettelbacher und O. Elattar, “Methodology for the estimation of the flexibilization potential of household consumers in electrical grids,” *ETG-Kongress*, Kassel, 2025.

7 Danksagung

Das Team der Arbeitsgruppe “Gebäude im zukünftigen Stromnetz” der Technischen Hochschule Nürnberg bedankt sich, auch im Namen aller Projektpartner, sehr herzlich beim “Bundesministerium für Wirtschaft und Energie” sowie beim “Projektträger Jülich” für die gewährte finanzielle Förderung des Forschungsvorhabens, ohne die eine Durchführung nicht möglich gewesen wäre.

Anhang A

Nr.	Art des Szenarios	Fragebogen- formulierung	Mögliche CO2/Strom/Kosten- Einsparung
Ausgangslage	Allgemeine Beschreibung Smart-Meter	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	Keine
Szenario 1	Anzeigemöglichkeit für Verbraucherinnen und Verbraucher	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch in einer App angezeigt. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	Den Verbraucherinnen und Verbrauchern stehen zusätzliche Informationen über ihren Stromverbrauch zur Verfügung. Diese können sie nutzen, um selbst aktiv zu werden und Energie zu sparen
Szenario 2	Anzeigemöglichkeit mit zusätzlichem Disaggregationsalgorithmus	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch in einer App angezeigt. Über einen intelligenten Algorithmus wird in der App dargestellt, welche	Den Verbraucherinnen und Verbrauchern stehen zusätzliche Informationen über ihren Stromverbrauch zur Verfügung – hier speziell auch der Verbrauch einzelner Haushaltsgeräte. Diese können sie nutzen, um selbst aktiv zu werden und Energie zu sparen. Je genauer und aufgliederter dem Nutzer sein Energieverbrauch

Nr.	Art des Szenarios	Fragebogen- formulierung	Mögliche CO2/Strom/Kosten- Einsparung
		Geräte jeweils am Gesamtstromverbrauch beteiligt sind. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	dargestellt wird, desto leichter fällt es ihm, daraufhin spezielle Energiesparmaßnahmen zu ergreifen.
Szenario 3	Anzeigemöglichkeit für Verbraucherinnen und Verbraucher + Kostensparhinweise	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	Kosteneinsparungen können entweder durch Stromeinsparungen (Szenario 4) oder durch Lastverschiebungen in Zeiten günstigeren Stroms (Szenario 7 und 9) erreicht werden.
Szenario 4	Anzeigemöglichkeit für Verbraucherinnen und Verbraucher + Stromsparhinweise	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Stromsparhinweisen in einer App angezeigt. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	Hier wird dem Verbraucher (im Vergleich zu Szenario 1 und 2) die CO2-Einsparung durch den Vorschlag konkreter Maßnahmen noch einfacher gemacht. Die Umsetzung der Maßnahmen liegt allerdings im Ermessen des Verbrauchers. Die CO2-Einsparung korreliert direkt mit dem Stromeinsparungen (bezogen auf die jeweilige CO2-Äquivalente des benutzten Stroms).

Nr.	Art des Szenarios	Fragebogen- formulierung	Mögliche CO2/Strom/Kosten- Einsparung
Szenario 5	Anzeigemöglichkeit für Verbraucherinnen und Verbraucher + Push-Benachrichtigungen für Kostensparhinweise	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Die Verbraucherinnen und Verbraucher erhalten Push-Benachrichtigungen mit Kostensparhinweisen.	Siehe Szenario 3. Der Unterschied liegt hierbei lediglich darin, dass die Verbraucherinnen und Verbraucher aktiv auf mögliche Kostensparmaßnahmen (und dadurch indirekt auch CO2-Sparmaßnahmen) hingewiesen werden. Es ist somit wahrscheinlicher, dass sie diese Einsparmaßnahmen ergreifen werden.
Szenario 6	Anzeigemöglichkeit für Verbraucherinnen und Verbraucher + Push-Benachrichtigungen für Stromsparhinweise	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Die Verbraucherinnen und Verbraucher erhalten Push-Benachrichtigungen mit Stromsparhinweisen.	Siehe Szenario 4. Der Unterschied liegt hierbei lediglich darin, dass die Verbraucherinnen und Verbraucher aktiv auf mögliche Stromsparmaßnahmen (und dadurch auch CO2-Sparmaßnahmen) hingewiesen werden. Es ist somit wahrscheinlicher, dass sie diese Einsparmaßnahmen ergreifen werden.
Szenario 7	Anzeigemöglichkeit für	Ein digitaler Stromzähler sendet anonymisiert alle 15min	Es wird angenommen, dass die Nutzung von PV-Strom aus der

Nr.	Art des Szenarios	Fragebogen- formulierung	Mögliche CO2/Strom/Kosten- Einsparung
	<p>Verbraucherinnen und Verbraucher +</p> <p>Push-Benachrichtigungen für Kostensparhinweise für den Betrieb von Geräten, wenn Strom aus eigener PV-Anlage verfügbar</p>	<p>den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Die Verbraucherinnen und Verbraucher erhalten Push-Benachrichtigungen mit Kostensparhinweisen für Betrieb von Geräten in Zeiten von günstigem Strom aus eigener PV-Anlage. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.</p>	<p>eigenen Anlage eine CO2-Einsparung im Vergleich zur Nutzung von Netzstrom darstellt. Somit können, wenn der Nutzer die Kostensparhinweise aus den Push-Benachrichtigungen berücksichtigt, CO2-Einsparungen erzielt werden.</p>
Szenario 8	<p>Anzeigemöglichkeit für Verbraucherinnen und Verbraucher +</p> <p>Push-Benachrichtigungen für Kostensparhinweise für Betrieb von Geräten in Zeiten von günstigem Strom bei variablen Tarifen</p>	<p>Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Die Verbraucherinnen und Verbraucher erhalten Push-Benachrichtigungen mit Kostensparhinweisen,</p>	<p>Günstiger Strom ist vor allem in den Zeiten einer hohen Stromerzeugung aus erneuerbaren Energien verfügbar. Werden die Kostensparhinweise aus den Push-Nachrichten vom Nutzer umgesetzt, kann hiermit in der Regel auch CO2 eingespart werden.</p> <p>Im Juni 2023 zum Beispiel schwankte der CO2-Emissionsfaktor des deutschen Strommixes zwischen 134 g CO2/kWh und 668 g CO2/kWh, je nach</p>

Nr.	Art des Szenarios	Fragebogen- formulierung	Mögliche CO2/Strom/Kosten- Einsparung
		<p>wenn im variablen Stromtarif Strom günstig verfügbar ist. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.</p> <p>(Variabler Stromtarif: Schwankungen in den Börsenstrompreisen werden hierbei an den Kunden weitergegeben; die Kundin oder der Kunde hat somit die Möglichkeit, Geld zu sparen, wenn er den Betrieb gewisser Geräte in Zeiträume verschiebt, in denen dies das Netz entlastet)</p>	<p>Zeitpunkt, an dem der Strom bezogen wurde [6].</p>
Szenario 9	<p>Anzeigemöglichkeit für Verbraucherinnen und Verbraucher + Automatisierungsmöglichkeit für steuerbare Haushaltsgeräte, wenn überschüssiger Strom aus eigener PV-Anlage verfügbar ist.</p>	<p>Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Steuerbare Haushaltsgeräte (bspw. Waschmaschine, Spülmaschine, Ladevorgang E-Auto) werden automatisch gesteuert/ betrieben, wenn PV-Strom aus eigener Anlage</p>	<p>Die Nutzung von PV-Strom aus der eigenen Anlage stellt im Normalfall eine CO2-Einsparung im Vergleich zur Nutzung von Netzstrom dar. Der Unterschied zu Szenario 7 liegt hierbei darin, dass die Kostensparmaßnahme automatisch ergriffen wird und nicht im Ermessen der Nutzerin oder des Nutzers liegt bzw. nicht speziell ergriffen werden muss. Es ist hiermit eine höhere CO2-Einsparung zu erreichen.</p>

Nr.	Art des Szenarios	Fragebogen- formulierung	Mögliche CO2/Strom/Kosten- Einsparung
		überschüssig vorhanden ist. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	
Szenario 10	Anzeigemöglichkeit für Verbraucherinnen und Verbraucher + Automatisierungsmöglichkeit für steuerbare Haushaltsgeräte, wenn in variablen Stromtarifen günstiger Strom verfügbar ist.	Ein digitaler Stromzähler sendet anonymisiert alle 15min den Stromverbrauch an den Verteilnetzbetreiber, Messstellenbetreiber und Energielieferanten. Den Verbraucherinnen und Verbrauchern wird ihr Echtzeitstromverbrauch mit Kostensparhinweisen in einer App angezeigt. Steuerbare Haushaltsgeräte (bspw. Waschmaschine, Spülmaschine, Ladevorgang E-Auto) werden automatisch gesteuert/ betrieben, wenn im variablen Stromtarif Strom günstig verfügbar ist. Diese Daten sind sicher, anonym und vor Missbrauch geschützt.	Günstiger Strom ist vor allem in den Zeiten einer hohen Stromerzeugung aus erneuerbaren Energien verfügbar. Der Unterschied zu Szenario 8 liegt hierbei darin, dass die Kostensparmaßnahme automatisch ergriffen wird und nicht im Ermessen der Nutzerin oder des Nutzers liegt bzw. nicht speziell ergriffen werden muss. Es ist hiermit eine höhere CO2-Einsparung zu erreichen.

Identifying electricity consumption of individual household devices by using smart meter data and AI technologies

Kyriaki Koutrouveli¹, Omar Elattar¹, Christiane Dettelbacher¹, Ivana Mladenovic¹

¹ Faculty of Electrical Engineering, Precision Engineering and Information Technology, Technische Hochschule Nuernberg Georg Simon Ohm, Germany
Kyriaki.koutrouveli@th-nuernberg.de, omar.elattar@th-nuernberg.de,
Christiane.dettelbacher@th-nuernberg.de, ivana.mladenovic@th-nuernberg.de

Abstract. In 2023, Germany's net electricity use was 467 TWh, with households contributing 28% of this total. Their proactive involvement is crucial for advancing the energy transition, alongside industrial efforts. Within a research project, a web application has been developed that processes and transparently displays household energy data, enabling users to observe and evaluate their energy consumption behavior. Its main goal is to motivate the users to participate in the energy transition in the short, medium, and long term through artificial intelligence. This paper presents the utilization of artificial intelligence to identify the energy consumption of individual appliances through the disaggregation of smart meter data of the households. Three households of a row-house complex with different consumer behavior were selected as examples for the analysis. Moreover, a distinction was made between the flexible and non-flexible portions of consumption. It was shown that the non-flexible share of household electricity consumption can be determined with an accuracy over 90%. Therefore, household residents can be provided with useful information on this consumption share with minimal effort and without additional measurements just by using the smart meter data, as it is planned as part of the smart meter rollout. Estimating the flexible share was more difficult, as appliances such as washing machines and dishwashers were difficult to analyze due to their less frequent use and low temporal data resolution. Combining the consumption of several flexible appliances led to a significant improvement of the results from 53,9% to 72% disaggregation accuracy across all households and appliances.

Keywords: Smart metering, NILM, LoRaWAN-Monitoring

1 INTRODUCTION

The household sector accounts for a significant proportion of total electricity consumption in Germany. According to the German Association of Energy and Water Industries, the net electricity consumption in Germany in 2023 was around 467 TWh, with households accounting for 28% of this. In addition, electricity consumption in the transport sector will

increase with the further penetration of electromobility. At the same time, the installed capacity of photovoltaic systems is growing rapidly. The demand for electrical energy in the heating sector will also increase due to the growing use of heat pumps. It is to be expected that these developments will become even more apparent in the electricity consumption of the household sector in the future. The active participation of households, alongside the contributions of industry and commerce, is therefore a decisive factor for the success of the energy transition. The publicly funded research project “Verbraucherpartizipation an der Energiewende durch KI-Technologien und daten-basierte Mehrwertdienste” (EVEKT) (Increasing consumer participation in the energy transition through AI technologies and data-based value-added services) is addressing precisely those areas where rising electricity consumption and the growing importance of renewable energies require a targeted solution. The aim is to raise residents' awareness of the benefits of energy-efficient self-consumption and flexible electricity consumption. For this purpose, the electricity consumption of individual households in a district with central PV generation and heating from heat pumps is recorded and analyzed using smart electricity meters. A user-friendly web application provides personalized information to encourage users to make informed decisions and promote more flexible consumption behavior.

This article focuses on the utilization of artificial intelligence to identify the energy consumption of individual appliances through the disaggregation of smart meter data of the households. A distinction is made between base load (non-flexible share) and flexible share of consumption. At the same time, the possibilities and limitations of existing machine learning algorithms are analyzed and discussed. This paper first presents an overview of the current state of research on disaggregation algorithms for consumption data. The methodology used is then described and the results are shown and discussed for three households as examples. Finally, the last section summarizes the key findings and offers an outlook.

1.1 State of research on the disaggregation of energy consumption data with low sampling rates

Disaggregation of electricity consumption, also known as non-intrusive load monitoring (NILM), describes the process of breaking down the total consumption of a household or building into the contributions of individual appliances, usually using algorithmic methods. In order to obtain reliable and usable information on appliance usage, it is essential to implement a suitable disaggregation method that considers the specific requirements of the households under consideration. Most methods in the literature require active power measurement data with very high resolution (≤ 1 s) and/or additional measurement data such as reactive power, current and voltage measurements, weather data, etc. One challenge here is the low resolution of the real measurement data (15-min intervals) of the smart meters in the households under consideration, although this will also become common practice for smart meter rollouts in the future. The NILM approaches known in the literature, which were used for the disaggregation of data with a sampling rate of ≥ 1 min, are described below.

NILM architectures and data sets. NILM methods based on machine learning are increasingly used to solve the disaggregation problem. NILM methods with high sampling rate data are most commonly used [1]. Methods that are applied to low-resolution data, on the other hand, are less common. Examples include K-Nearest Neighbors (K-NN) [2], Decision Trees (DT) and Support Vector Machines (SVM) [3]. More recently, methods based on deep neural networks have also been tested on 1-min [4], and hourly [5] data. Particularly noteworthy are approaches based on sequence-to-point learning, which have demonstrated high accuracy [6]. Algorithms based on Generative Adversarial Networks (GAN) were also used and tested in data sets with 1-minute [7] and 10-minute resolution [8].

In addition to machine learning, graph-based methods were also used for pattern recognition. In [9], Zhao et al. developed a NILM method based on graph signal processing (GSP) and tested it in 1-min data. A variant of this method was also used in hourly data [5]. Other disaggregation methods such as discriminative sparse coding [10], semi-binary nonnegative matrix factorization (SBNMF) [11] or optimization [5] were used in low-resolution data.

For the development and testing of the NILM methods, mainly public data sets with measured household consumption data including measurements of individual household appliances are used. The datasets used in the literature for the disaggregation of consumption data are mainly the REDD [12], REFIT [13], AMPdS [14], UK-Dale [15] and Dataport [16] datasets.

Evaluation metrics. Over the years, very different evaluation metrics have been used to evaluate the various NILM methods, such as F-score, match rate (MR), energy consumption accuracy (E_{ACC} or TECA), mean absolute error (MAE), sum of absolute errors (SAE) or root mean square error (RMSE). MR and E_{ACC} [17] [5] are particularly suitable for the evaluation of NILM methods with very low resolution data. The energy consumption accuracy, E_{ACC} , as defined in (1), is defined as the total error of the estimated energy \hat{p}_m^τ normalized by the actual energy consumption p_m^τ in each time interval and averaged over all devices T:

$$E_{Acc} = 1 - \frac{\sum_{\tau=1}^T |\hat{p}_m^\tau - p_m^\tau|}{2 \sum_{\tau=1}^T |p_m^\tau|} \quad (1)$$

$$MR = \frac{\sum_{\tau=1}^T \min\{p_m^\tau, \hat{p}_m^\tau\}}{\sum \max\{p_m^\tau, \hat{p}_m^\tau\}} \quad (2)$$

The match rate, MR (2) shows the overall matching accuracy between the actual p_m^τ and the estimated \hat{p}_m^τ energy consumption. It can assume values from 0 to 1, whereby a value approaching 1 or 0 indicates a good or poor match respectively. A detailed overview of the various evaluation metrics for assessing the NILM approaches can be found in [17].

The following table provides an overview of the NILM architectures described above and their properties. It can be seen that a direct comparison of the approaches is not possible because they were implemented with different data sets of different sampling rates and different metrics were used for their evaluation. Nevertheless, the table illustrates the importance of selecting suitable methods for corresponding data sets, which will be demonstrated in the next section using a real example.

Table 1. NILM-Methods for data with very low sampling rate

Method	Publication	Year	Metric	Accuracy	Data set	Sampling rate
CNN	[5]	2020	E _{ACC} , MR	69.5%,63%	REFIT 4,8	1 hour
K-NN	[2]	2018	E _{ACC}	50% (15 Min) 58.2% (1 h)	REDD, REFIT 1,2, AMPds	15 Min/1 h
SVM, DT, K-NN	[3]	2015	FM-Score	~68 % / 50%	IRISE	10 Min/1 h
GAN	[8]	2022	E _{ACC}	58.9% (REDD) 72.15 (Dataport)	REDD 1,2,3,4,6 Dataport	10 Min
GSP	[5]	2020	E _{ACC} , MR	56.1%, 30.6%	REFIT 4,8	1 hour
DDSC	[10]	2017	E _{ACC} , MR	58.9%	REDD 1,4,6 Dataport	10 Min
SBNMF	[11]	2019	MR	60%	9 households in Japan	30 Min
OPT	[5]	2020	E _{ACC} , MR	63.7%, 47.3%	REFIT 4,8	1 hour
GAN	[7]	2021	MAE (W)	35.2 (REFIT) 37.5 (AMPds)	REFIT, AMPds	1 Min
GSP	[9]	2016	FM-Score	60%	REDD 1,2,6 REFIT 8	1 Min
CNN	[4]	2020	MAE (W)	25.8 (House 1) 19.47 (House 2)	UK-Dale (3 devices)	1 Min

2 METHODOLOGY FOR DISSAGREGATION OF THE ELECTRICAL ENERGY CONSUMPTION

Prior to disaggregating the electricity consumption, a distinction was made between the flexible and non-flexible portions of consumption. The flexible share of consumption comprises the electricity consumption of appliances whose operation can be postponed. Within this flexible share, large appliances such as washing machines, dishwashers and tumble dryers are of particular importance. The non-flexible portion of household consumption, on the other hand, includes the base load (continuous operation or standby), as well as the electricity consumption of approximately periodically running consumers, such as refrigerators and freezers. For the analysis, three households with very different consumer behavior of the terraced house complex were selected for consideration. Consumption data of selected energy-intensive household appliances in these households have been recorded every minute using LoRaWAN technology since the beginning of 2024. This data is used both to train the NILM algorithms and to test and evaluate the disaggregation results. The total household consumption has been recorded every 15 minutes since 2017. It should be emphasized that this is exclusively the electricity consumption of household appliances, without considering the heating sector, as this is recorded centrally and separately in the district,

just like the PV system. To determine the non-flexible share of consumption, the first step was to develop and test a method for detecting the entire base load based on the algorithm proposed in [5]. The idle consumption data recorded during the night hours are used as input values. The daily base load of the previous day is determined and evaluated daily using the developed algorithm. The calculated daily base load also contains the idle consumption of the refrigerators and freezers. Consumption peaks caused by the use of these appliances are filtered out by the algorithm. In order to identify the consumption of individual devices, both flexible and not-flexible, three machine-learning NILM approaches were selected based on the literature review, since they are considered the most promising. These include the CNN architecture based on Seq2Point learning, as described in [6], and the EnerGAN algorithm from [7]. Both approaches have shown good results in the literature for data sets with low temporal resolution. In addition, a CNN architecture based on heat maps, inspired by [18], was implemented. A resolution of 15 min was adopted for all data. The applied algorithms were trained over a period of 26 weeks and tested over a period of 11 weeks.

3 EVALUATION OF THE RESULTS

For the evaluation of the algorithms, the metrics E_{ACC} and MR, as defined in (1) and (2), are used. In order to achieve usable and relevant results, the period is divided into 8-hour windows. The aim is to determine whether the appliances were operated during periods of high grid load or while increased generation of renewable energy. The selected households (H1, H2, H3) have different numbers of intensive consumers and consumer behavior.

3.1 Non-flexible shares of electricity consumption

The actual base load can be reliably determined during the holiday periods, as consumption during this phase consists exclusively of the base load. Therefore, the consumption data from these periods serve as a reference for evaluating the accuracy of the algorithm. Fig. 1 shows the average daily electricity consumption and the calculated average daily base load for the three houses during the vacation phases in 2023. It can be seen that the algorithm is able to calculate the daily base load with very high accuracy.




Fig. 1 Calculated average daily base load (orange) compared to average daily consumption (blue) during vacation periods

In addition, the most electricity-intensive appliances from the base load (fridges and freezers) were disaggregated using the selected algorithms. Table 2 shows the daily E_{ACC} and MR values respectively. All three machine learning algorithms (IMG-NILM, Seq2Point, EnerGAN) have provided results with very high accuracy, with Seq2Point consistently providing results with the highest agreement rate across all devices, which is in line with the literature [6]. However, although the machine learning algorithms require training data, there is an opportunity to apply pre-trained algorithms to unseen data. It has been shown that the Seq2Point algorithm is highly transferable across domains [19].

Table 2. E_{ACC} and MR (8-hour window) (E_{ACC}/MR) for the fridges and freezers in the three households KS: Fridge, GT: Freezer

	H1		H2		H3	
Device	KS	KS1	KS2	KS1	KS2	GT
IMG-NILM	0.92/0.85	0.92/0.84	0.89/0.78	0.92/0.86	0.92/0.84	0.97/0.93
Seq2Point	0.92/0.86	0.93/0.86	0.89/0.79	0.92/0.86	0.88/0.77	0.96/0.93
EnerGAN	0.91/0.82	0.88/0.78	0.88/0.77	0.89/0.78	0.89/0.77	0.93/0.87




Fig. 2. Disaggregation results (testing period of 11 weeks) for the refrigerators and freezer

As shown above, the non-flexible share of electricity consumption in a household can be determined with a high degree of accuracy - both as a sum for the entire base load and proportionally for periodically running appliances such as fridges and freezers. Therefore, the household residents can be provided with useful information on this consumption share with minimal effort and without additional measurements just by using the 15 min. data from the smart meters, as it is planned as part of the smart meter rollout. This is expected to lead to a general reduction in the household's overall electricity consumption.

3.2 Flexible share of consumption

The results of the disaggregation of the flexible household appliances are presented below. WM stands for washing machine, GS for dishwasher and WT for tumble dryer. In contrast

to fridges and freezers, these appliances are used less frequently and often only a few times a week. In combination with the low resolution of the measurement data, the infrequent use poses a challenge for the algorithms, as there are not enough operating cycles available to enable effective learning and precise disaggregation. Table 3 shows the results of the disaggregation for the flexible household consumers. EnerGAN did not deliver satisfactory results for H1 and H2. In the case of EnerGAN, only E_{ACC} is not sufficient to evaluate the results of the algorithms as the values of about 0.5 may be misleading. These devices were switched off most of the time and usually only operated once a day. Since the algorithm provided almost zero results or significantly underestimated the consumption (Fig. 3), the E_{ACC} value reflects the random match with this base value rather than the ability of the algorithm to recognize the operation of the appliance during its short active phases. Therefore, additional metrics such as MR are necessary to evaluate the performance of the algorithm. Seq2Point and IMG-NILM delivered significantly better results, with Seq2Point consistently achieving the best results. In H1, the dishwasher was identified with a particularly high E_{ACC} and MR. H1 is characterized by low energy consumption and only few household appliances with high power consumption. As a result, there is less noise in electricity consumption in this household, which facilitates disaggregation. However, as the washing machine in this household was only operated infrequently, the algorithms were unable to provide satisfactory performance here.

Table 3. E_{ACC} and MR (8-hour window) (E_{ACC}/MR) for the short-term intensive electricity consumers in households H1, H2 and H3

	H1		H2		H3		
Device	GS	WM	WT	WM	GS	WT	WM
IMG-NILM	0.53/0.20	0.11/0.05	0.52/0.31	0.51/0.38	0.35/0.29	0.28/0.32	0.48/0.36
Seq2Point	0.8/0.7	-/0.02	0.57/0.29	0.64/0.48	0.59/0.42	0.64/0.37	0.53/0.32
EnerGAN	0.55/0.15	0.48/0	0.49/0.04	0.50/0.04	0.56/0.37	0.67/0.44	0.50/0.15




Fig. 3 Disaggregation results (testing period of 11 weeks) for the short-term intensive electricity consumers in households

The algorithm with the best performance, Seq2Point, was able to achieve an energy consumption accuracy of 53.9% across all three households and appliances. The results are consistent with findings from the literature for very low temporal resolution data (Table 1). Since our focus is on determining whether any flexible high consumption appliance was in operation within this period, in the next step we will try to increase the disaggregation accuracy by disaggregating the cumulative flexible consumption per household instead of the individual appliances. It is expected that merging the consumption of several household appliances can provide more reliable results, especially for data with low temporal resolution, as individual appliance patterns are often difficult and therefore unreliable to recognize. The results of the disaggregation for each household and the respective method for the cumulative appliances shown in Table 4 confirm the expectations. A significant increase in disaggregation accuracy is evident for all three households.

Table 4. E_{ACC} and MR (8-hour window) (E_{ACC}/MR) for cumulative intensive electricity appliances

	H1 (GS+WM)		H2 (WM+WT)		H3 (GS+WM+WT)	
	E_{ACC}	MR	E_{ACC}	MR	E_{ACC}	MR
IMG-NILM	0.60	0.32	0.64	0.44	0.61	0.53
Seq2Point	0.66	0.56	0.59	0.48	0.81	0.70
EnerGAN	0.67	0.43	0.68	0.39	0.81	0.66

Aggregating the consumption of several household appliances can provide more reliable results, especially for data with low temporal resolution. This method is well suited for analyses aimed at overarching consumption trends, such as estimating total energy demand. Thus, the consumption of the washing machines, dishwashers and tumble dryers in each household was summed up and presented as a single appliance to the algorithms for training.

The results of the disaggregation vary between the individual households. In H2 and H3, we saw an improvement in the results across all algorithms. H3 shows a significant improvement in both E_{ACC} and MR across all three algorithms. It was possible to disaggregate 81% of the total energy consumption of the three appliances. In H2, we also observed an increased MR. In H1, on the other hand, although aggregating the consumption of the washing machine and dishwasher improved the overall accuracy, the accuracy of the dishwasher was significantly higher before aggregation. This is due to the quite different load profile of the washing machine compared to the dishwasher, which made learning more difficult for the algorithm. EnerGAN delivered the best results across all households and appliances and was able to disaggregate 72% of the energy consumed. This represents a significant improvement on previous results.

4 CONCLUSION

The possibility to use NILM-Methods in order to provide household owners with targeted, personalized recommendations regarding their electricity consumption has been assessed.

A distinction was made between the flexible and non-flexible portions of consumption. Different disaggregation algorithms (Seq2Point, IMG-NILM, EnerGAN) were used to detect individual household appliances. It was shown that the non-flexible share of household electricity consumption can be determined with a high degree of accuracy - both as the entire base load of the house and proportionally for periodically running appliances such as refrigerators and freezers. Therefore, the household residents can be provided with useful information on this consumption share with minimal effort and without additional measurements just by using the smart meter data, as it is planned as part of the smart meter rollout. Estimating the flexible share was more difficult, as appliances such as washing machines and dishwashers were difficult to analyze due to their less frequent use and low temporal data resolution. Combining the consumption of several flexible appliances led to a significant improvement in the results.

NOMENCLATURE

p_m^τ	Mean actual energy consumption of device τ , kWh
\hat{p}_m^τ	Mean estimated energy consumption of device τ , kWh
E_{ACC}	Energy consumption accuracy, ND
MR	Match rate, ND

REFERENCES

1. P. A. Schirmer, I. Mporas: "Non-Intrusive Load Monitoring: A Review," IEEE Transactions on Smart Grid, vol. 14, no. 1, pp. 769-784, 2023, doi: 10.1109/TSG.2022.3189598.
2. B. Zhao, L. Stankovic, V. Stankovic: "Electricity usage profile disaggregation of hourly smart meter data", 2018 Poster session presented at 4th International Workshop on Non-Intrusive Load Monitoring, Austin, USA
3. K. Basu, V. Debusschere, S. Bacha, U. Maulik, S. Bondyopadhyay; "Nonintrusive Load Monitoring: A Temporal Multilabel Classification Approach," IEEE Transactions on Industrial Informatics, vol. 11, no. 1, pp. 262-270, 2015, doi: 10.1109/TII.2014.2361288.
4. L. Massidda, M. Marrocu, S. Manca: "Non-intrusive load disaggregation by convolutional neural network and multilabel classification," Appl. Sci., vol. 10, no. 4, p. 1454, 2020, doi: 10.3390/app10041454
5. B. Zhao, M. Ye, L. Stankovic, V. Stankovic: "Non-intrusive load disaggregation solutions for very low-rate smart meter data", Applied Energy, v. 268, 2020, doi: 10.1016/j.apenergy.2020.114949
6. C. Zhang, M. Zhong, Z. Wang, N. Goddard, C. Sutton, "Sequence-to-point learning with neural networks for nonintrusive load monitoring", The Thirty-Second AAAI Conference on Artificial Intelligence (AAAI-18), 2018
7. M. Kaselimi, A. Voulodimos, E. Protopapadakis, N. Doulamis and A. Doulamis, "EnerGAN: A generative adversarial network for energy disaggregation" ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Barcelona, Spain, 2020, pp. 1578-1582, doi: 10.1109/ICASSP40776.2020.9054342

8. A. Majumdar, "Trainingless Energy Disaggregation Without Plug-Level Sensing," in *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-8, 2022, Art no. 2504808, doi: 10.1109/TIM.2022.3152311
9. B. Zhao, L. Stankovic, V. Stankovic: "On a Training-Less Solution for Non-Intrusive Appliance Load Monitoring Using Graph Signal Processing," *IEEE Access*, vol. 4, pp. 1784-1799, 2016, doi: 10.1109/ACCESS.2016.255746
10. S. Singh and A. Majumdar, "Analysis Co-Sparse Coding for Energy Disaggregation," in *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 462-470, 2019, doi: 10.1109/TSG.2017.2743763
11. A. Miyasawa, Y. Fujimoto and Y. Hayashi, "Energy Disaggregation Based on Smart Metering Data via Semi-Binary Nonnegative Matrix Factorization" in *Energy and Buildings* 183, 2018, doi: 10.1016/j.enbuild.2018.10.030
12. J. Kolter and M. Johnson, "REDD: A Public Data Set for Energy Disaggregation Research." Available: <https://people.csail.mit.edu/mattjj/papers/kddsust2011.pdf>
13. D. Murray, L. Stankovic, and V. Stankovic, "An electrical load measurements dataset of United Kingdom households from a two-year longitudinal study," *Scientific Data*, vol. 4, no. 1, 2017, doi: 10.1038/sdata.2016.122
14. S. Makonin, F. Popowich, L. Bartram, B. Gill and I. V. Bajić, "AMPds: A public dataset for load disaggregation and eco-feedback research," 2013 *IEEE Electrical Power & Energy Conference*, Halifax, NS, Canada, 2013, pp. 1-6, doi: 10.1109/EPEC.2013.6802949
15. J. Kelly and W. Knottenbelt, "The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes," in *Scientific Data*, vol. 2, p. 150007, 2015, doi: 10.1038/sdata.2015.7
16. O. Parson et al., "Dataport and NILMTK: A building data set designed for non-intrusive load monitoring," 2015 *IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, Orlando, FL, USA, 2015, pp. 210-214, doi: 10.1109/GlobalSIP.2015.7418187
17. L. Pereira, N. Nunes: "Performance evaluation in non-intrusive load monitoring: Datasets, metrics, and tools—A review," *WIREs Data Mining and Knowledge Discovery*, vol. 8, no. 6, May 2018, doi: 10.1002/widm.1265.
18. Heat Maps J. Edmonds and Z. S. Abdallah, „IMG-NILM: A Deep learning NILM approach using energy heatmaps“, in *Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing*, New York, Association for Computing Machinery, 2023, pp. 1151-1153.
19. M. D’Incecco, S. Squartini and M. Zhong: "Transfer Learning for Non-Intrusive Load Monitoring," in *IEEE Transactions on Smart Grid*, vol. 11, no. 2, pp. 1419-1429, 2020, doi: 10.1109/TSG.2019.2938068.

ACKNOWLEDGEMENTS

The work was carried out as part of the project “Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien und datenbasierte Mehrwertdienste – EVEKT”, which is funded by the Federal Ministry for Economic Affairs and Climate Protection (funding priority: Energy transition and society, funding reference: 03EI5234A).

Methodik zur Abschätzung des Flexibilisierungspotentials von Haushaltsverbrauchern in elektrischen Netzen

Methodology for the estimation of the flexibilization potential of household consumers in electrical grids

Kyriaki Koutrouveli, Omar Elattar, Christiane Dettelbacher, Ivana Mladenovic, Technische Hochschule Nürnberg Georg Simon Ohm, Nürnberg, Deutschland

kyriaki.koutrouveli@th-nuernberg.de, omar.elattar@th-nuernberg.de, christiane.dettelbacher@th-nuernberg.de
ivana.mladenovic@th-nuernberg.de

Kurzfassung

Der Haushaltssektor trägt wesentlich zum Stromverbrauch in Deutschland bei und wird durch Entwicklungen wie Elektromobilität und den verstärkten Einsatz von Wärmepumpen weiter ansteigen. In diesem Beitrag wird das Flexibilisierungspotenzial des Stromverbrauchs in Haushalten abgeschätzt, indem der flexible und nicht-flexible Anteil unter Verwendung intelligenter Stromzähler und Disaggregationsmethoden berechnet werden. Für die Analyse wurden drei Haushalte eines Reihenhauses mit sehr unterschiedlichem Verbraucherverhalten beispielhaft ausgewählt. Zur Bestimmung des Verbrauchs einzelner Geräte wurden verschiedene Disaggregationsalgorithmen getestet. Der nicht-flexible Anteil des Haushaltsstromverbrauchs konnte sowohl als gesamte Grundlast des Hauses als auch anteilig für periodisch laufende Geräte wie Kühl- und Gefrierschränke mit hoher Genauigkeit bestimmt werden. Die Abschätzung des flexiblen Anteils einzelner flexibel einsetzbarer Geräte wie Waschmaschinen und Geschirrspüler war schwieriger, da diese aufgrund ihrer zeitlich irregulären Nutzung und der niedrigen Datenauflösung schwieriger zu disaggregieren sind. Das Summieren der Verbräuche mehrerer flexibel einsetzbarer Geräte führte zu einer deutlichen Verbesserung der Ergebnisse. Es wurde gezeigt, dass das Flexibilisierungspotential, entweder durch das Herausfiltern des nicht-flexiblen Anteils des Verbrauchs vom Gesamtverbrauch oder durch die direkte Disaggregation der flexiblen Haushaltsverbraucher, mit höherer Genauigkeit abgeschätzt werden kann. Der flexible Verbrauchsanteil kann nicht pauschalisiert werden und liegt bei den ausgewählten Haushalten zwischen 6,9 % und 39,4 %.

Abstract

The household sector makes a significant contribution to electricity consumption in Germany and will continue to rise due to developments such as electromobility and the increased use of heat pumps. In this article, the potential for flexibilization of electricity consumption in households is estimated by calculating the flexible and non-flexible share using smart meters and disaggregation methods. Three households in a terraced house complex with very different consumer behaviour were selected as examples for the analysis. Various disaggregation algorithms were tested to determine the consumption of individual appliances. The non-flexible share of household electricity consumption could be determined with high accuracy both for the total base load of the house and for individual periodically running appliances such as refrigerators and freezers. It was more difficult to estimate the flexible share of only flexibly usable appliances such as washing machines and dishwashers, as these are more difficult to disaggregate due to their irregular use over time and the low data resolution. Summing up the consumption of several flexible appliances led to a significant improvement in the results. It was shown that the flexibilization potential can be estimated with higher accuracy either by filtering out the non-flexible part of the consumption from the total consumption or by directly disaggregating the flexible household consumers. The flexible share of consumption cannot be generalized and lies between 6.9 % and 39.4 % for selected households.

1 Einleitung

Der Haushaltssektor trägt einen erheblichen Anteil am gesamten elektrischen Energieverbrauch in Deutschland. Laut dem Bundesverband der Energie- und Wasserwirtschaft, lag im Jahr 2023 der Nettostromverbrauch in Deutschland bei rund 467 TWh, wobei die Haushalte einen Anteil von 28 % daran hatten. Darüber hinaus wird, mit

weiterer Durchdringung von Elektromobilität, der Stromverbrauch im Verkehrssektor zunehmen. Gleichzeitig wächst die installierte Leistung von Photovoltaikanlagen rasch. Auch im Wärmesektor wird sich der Bedarf an elektrischer Energie durch einen steigenden Einsatz von Wärmepumpen erhöhen. Es ist zu erwarten, dass diese Entwicklungen sich zukünftig noch deutlicher im Stromverbrauch des Haushaltsektors sichtbar machen werden. Die

aktive Beteiligung der Haushalte ist daher, neben den Beiträgen von Industrie und Gewerbe, ein entscheidender Faktor für den Erfolg der Energiewende.

Vor diesem Hintergrund setzt das öffentlich geförderte Forschungsprojekt „Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien und daten-basierte Mehrwertdienste“ (EVEKT) genau dort an, wo der steigende Stromverbrauch und die wachsende Bedeutung von erneuerbaren Energien eine gezielte Lösung erfordern. Zu diesem Zweck wird in einem Quartier mit zentraler PV-Erzeugung und Heizung durch Wärmepumpen der Stromverbrauch einzelner Haushalte mit intelligenten Stromzählern erfasst und analysiert. Ziel ist es, die Bewohner für die Vorteile des energetisch effizienten Eigenverbrauchs und flexiblen Stromkonsums zu sensibilisieren.

Dieser Beitrag konzentriert sich auf eine Abschätzung des Flexibilisierungspotentials der Verbraucher durch Anwendung von Disaggregation des gesamten erfassten Haushaltsverbrauchs. Dabei wird unterschieden zwischen Grundlast (nicht-flexiblem Anteil) und flexiblem Anteil des Verbrauchs. Gleichzeitig werden die Möglichkeiten und Grenzen bestehender Machine-Learning-Algorithmen analysiert und diskutiert.

In diesem Paper wird zunächst eine Übersicht über den Stand der Forschung zu den Disaggregationsalgorithmen von Verbrauchsdaten präsentiert. Folgend wird die angewandte Methodik beschrieben und es werden die Ergebnisse beispielhaft für drei Haushalte gezeigt und diskutiert. Abschließend fasst der letzte Abschnitt die zentralen Erkenntnisse zusammen und bietet einen Ausblick.

1.1 Stand der Forschung zur Disaggregation von Energieverbrauchsdaten mit niedrigen Abstraten

Die Disaggregation des Stromverbrauchs, auch als Non-Intrusive Load Monitoring (NILM) bekannt, beschreibt den Prozess, den Gesamtverbrauch eines Haushalts oder Gebäudes in die Beiträge einzelner Geräte aufzuschlüsseln, meist mithilfe algorithmischer Methoden. Um zuverlässige und verwendbare Informationen über die Gerätenutzung zu gewinnen, ist es von zentraler Bedeutung, eine geeignete Disaggregationsmethode zu implementieren, die die spezifischen Anforderungen der betrachteten Haushalte berücksichtigt. Die meisten Methoden in der Literatur erfordern Wirkleistungsmessdaten mit sehr hoher Auflösung (≤ 1 Sekunde) und/oder zusätzlichen Messdaten wie Blindleistung, Strom- und Spannungsmessungen, Wetterdaten usw. Eine Herausforderung besteht dabei in der niedrigen Auflösung der realen Messdaten (15-Minuten-Intervalle) der Smart Meter in den betrachteten Haushalten, was jedoch zukünftig auch bei Smart Metern Rollout gängige Praxis sein wird. In Folgenden werden die in der Literatur bekannten NILM-Ansätze, welche für die Disaggregation von Daten mit einer Abstrakte von ≥ 1 Min benutzt wurden, beschrieben.

1.1.1 NILM-Architekturen und Datensätze

NILM-Methoden, die auf maschinellem Lernen basieren, werden zunehmend zur Lösung des Disaggregationsproblems eingesetzt. Dabei kommen am häufigsten NILM-Methoden für Daten hoher Abstrakte zum Einsatz [1]. Methoden, die auf Daten mit niedriger Auflösung angewendet werden, sind hingegen seltener. Beispiele hierfür sind die K-Nearest Neighbours (K-NN) [3], Decision Trees (DT) und Support Vector Machines (SVM) [4]. In jüngerer Zeit wurden auch Methoden auf Basis tiefer neuronaler Netze eingesetzt und in 1-min [5] und stündlichen [6] Daten getestet. Besonders hervorzuheben sind Ansätze auf Basis des „Sequence-to-Point“-Learnings, die eine hohe Genauigkeit zeigen konnten [6][7]. Auch Algorithmen, die auf Generative Adversarial Networks (GAN) basieren, wurden eingesetzt und in Datensätzen mit 1-minütiger [9] und 10-minütiger Auflösung [10] getestet.

Neben maschinellem Lernen wurden auch graphbasierte Methoden zur Mustererkennung eingesetzt. Zhao et al. haben in [8] eine NILM-Methode entwickelt, die auf Graph Signal Processing (GSP) basiert und diese mit 1-min Daten getestet. Eine Variante dieser Methode wurde auch mit stündlichen Daten getestet [6]. Weitere Disaggregationsmethoden wie Discriminative Sparse Coding [11], semi-binary nonnegative matrix factorization (SBNMF) [12] oder Optimization [6] wurden ebenfalls mit Daten mit niedriger Auflösung eingesetzt.

Für die Entwicklung und das Testen der NILM-Methoden werden überwiegend öffentliche Datensätze mit gemessenen Haushaltsverbrauchsdaten einschließlich Messungen von einzelnen Haushaltsgeräten verwendet. Die Datensätze, welche in der Literatur für die Disaggregation von Verbrauchsdaten eingesetzt werden, sind hauptsächlich folgende: REDD [13], REFIT [14], AMPdS [15], UK-Dale [16] und Dataport [17].

1.1.2 Bewertungsmetriken

Zur Bewertung der verschiedenen NILM-Methoden wurden im Laufe der Jahre sehr unterschiedliche Evaluationsmetriken verwendet, wie F-Score, Match-Rate (MR), Energieverbrauchsgenauigkeit (E_{ACC} oder TECA-Total Energy Correctly Assigned), Mean Absolute Error (MAE), Sum of Absolute Errors (SAE) oder Root Mean Square Error (RMSE). Besonders geeignet für die Bewertung von NILM-Methoden mit Daten von sehr niedriger Auflösung sind vor allem MR und E_{ACC} [2] [6]. Die Energieverbrauchsgenauigkeit, E_{ACC} , welche in (1) definiert ist, wird als der Gesamtfehler der abgeschätzten Energie \hat{p}_m^τ normalisiert durch den tatsächlichen Energieverbrauch p_m^τ in jedem Zeitabschnitt und gemittelt über alle Geräte T definiert:

$$E_{ACC} = 1 - \frac{\sum_{\tau=1}^T |\hat{p}_m^\tau - p_m^\tau|}{2 \sum_{\tau=1}^T |p_m^\tau|} \quad (1)$$

$$MR = \frac{\sum_{\tau=1}^T \min\{p_m^\tau, \hat{p}_m^\tau\}}{\sum \max\{p_m^\tau, \hat{p}_m^\tau\}} \quad (2)$$

Die Match-Quote, MR (2) zeigt die gesamte Übereinstimmungsgenauigkeit zwischen dem tatsächlichen p_m^r und dem geschätzten \hat{p}_m^r Energieverbrauch. Sie kann Werte von 0 bis 1 annehmen, wobei ein Wert der sich an 1 bzw. 0 nähert, eine gute bzw. schlechte Übereinstimmung andeutet. Eine ausführliche Übersicht der verschiedenen Evaluationsmetriken zur Bewertung der NILM-Ansätze findet man in [2].

Folgende Tabelle bietet einen Überblick der oben beschriebenen NILM Architekturen und deren Eigenschaften. Es

ist ersichtlich, dass ein direkter Vergleich der Ansätze nicht möglich ist, da sie mit unterschiedlichen Datensätze unterschiedlichster Abtastraten implementiert und für ihre Evaluation unterschiedliche Metriken verwendet wurden. Dennoch, legt die Tabelle die Wichtigkeit der Auswahl geeigneter Methoden für entsprechende Datensätze dar, was im kommenden Abschnitt konkret an einem realen Beispiel demonstriert wird.

Method	Publikation	Jahr	Metrik	Genauigkeit	Datensatz	Abtastrate
CNN	[6]	2020	E_{ACC} , MR	69,5%,63%	REFIT 4,8	1 St.
CNN	[5]	2020	MAE (W)	25,8 (Haus 1) 19,47 (Haus 2)	UK-Dale (3 Geräte)	1 Min
K-NN	[3]	2018	E_{ACC}	50% (15 Min) 58,2% (1 St.)	REDD, REFIT 1,2, AMPds	15 Min/1 Stunde
SVM, DT, K-NN	[4]	2015	F_M -Score	~68 % / 50%	IRISE	10 Min/1 Stunde
GAN	[9]	2021	MAE (W)	35,2 (REFIT) 37,5 (AMPds)	REFIT, AMPds	1 Min
GAN	[10]	2022	E_{ACC}	58,9% (REDD) 72,15 (Dataport)	REDD 1,2,3,4,6 Dataport	10 Min
GSP	[8]	2016	F_M -Score	60%	REDD 1,2,6 REFIT 8	1 Min
GSP	[6]	2020	E_{ACC} , MR	56,1%, 30,6%	REFIT 4,8	1 Stunde
DDSC	[11]	2017	E_{ACC} , MR	58,9%	REDD 1,4,6 Dataport	10 Min
SBNMF	[12]	2019	MR	60%	9 Haushalte in Japan	30 Min
OPT	[6]	2020	E_{ACC} , MR	63,7%, 47,3%	REFIT 4,8	1 Stunde

Tabelle 1 NILM-Methoden für Daten mit sehrniedriger Abtastrate

2 Methodik zur Abschätzung des Flexibilisierungspotentials

Um das Flexibilisierungspotenzial der Haushalte abzuschätzen, ist es entscheidend, zwischen dem flexiblen und nicht flexiblen Anteil des Verbrauchs zu unterscheiden. Der flexible Anteil des Verbrauchs umfasst den Stromverbrauch von Geräten, deren Betrieb zeitlich verschoben werden kann. Innerhalb dieses flexiblen Anteils sind insbesondere Großverbraucher wie Waschmaschinen, Geschirrspüler oder Wäschetrockner von besonderer Bedeutung. Der nicht flexible Anteil des Haushaltsverbrauchs hingegen umfasst die Grundlast (Dauerbetrieb oder Standby), sowie den Stromverbrauch von näherungsweise periodisch laufenden Verbrauchern, wie z. B. Kühl- und Gefrierschränke oder -geräte.

Für die Analyse wurden drei Haushalte des Reihenhauskomplexes mit sehr unterschiedlichem Verbraucherverhalten ausgewählt. Um die geeigneten Haushalte und Geräte für ein Intensiv-Monitoring zu bestimmen, wurde eine Umfrage im betrachteten Quartier durchgeführt. Damit wurden Informationen über Verbrauchsgewohnheiten, die Art und Nutzung der Haushaltsgeräte sowie das allgemeine Verbraucherverhalten gewonnen. Die Auswertung der Umfrage diente einerseits dazu, passende Haushalte für die Untersuchung auszuwählen, und andererseits dazu, Geräte mit dem voraussichtlich höchsten Jahresverbrauch für das Monitoring zu identifizieren. Im Rahmen des Intensiv-Monitorings werden stromintensive Haushaltsgeräte einzeln überwacht. Seit Anfang 2024 werden diese Geräte mithilfe der LoRaWAN-Technologie im Minutentakt erfasst. Diese Daten dienen sowohl dem Training der NILM-Algorithmen als auch der Prüfung und Bewertung der Disaggregationsergebnisse. Der gesamte Haushaltsverbrauch wird be-

reits seit 2017 im 15-Minuten-Takt erfasst. Es ist zu betonen, dass es sich ausschließlich um den Stromverbrauch der Haushaltsgeräte, ohne Berücksichtigung des Wärmesektors handelt, da dieser im Quartier, genauso wie die PV-Anlage, zentral und separat erfasst wird. Zur Bestimmung des nicht-flexiblen Anteils des Verbrauchs wurde als erstes eine Methode zur Erkennung der Grundlast auf Basis des in [6] vorgeschlagenen Algorithmus entwickelt und getestet. Als Eingabewerte dienen die Ruheverbrauchsdaten, die in den Nachtstunden erfasst wurden. Die Tagesgrundlast des vorherigen Tages wird täglich mithilfe des entwickelten Algorithmus ermittelt und bewertet. Die berechnete Tagesgrundlast enthält auch den Ruheverbrauch der Kühl- und Gefriergeräte. Verbrauchsspitzen, die durch die Nutzung dieser Geräte entstehen, werden vom Algorithmus rausgefiltert.

Zur Bestimmung des flexiblen Anteils des Verbrauchs ist es wichtig, die Grundlast sowie die gelegentlichen Lastspitzen von näherungsweise dauerhaft bzw. periodisch laufenden Verbrauchern auszuschließen. Hierzu gibt es zwei mögliche Vorgehen. Entweder werden die flexiblen Haushaltsverbraucher direkt identifiziert oder es wird der nicht-flexible Anteil des Verbrauchs abgeschätzt und vom Gesamtverbrauch rausgenommen. Für beide Optionen wurden ausgewählte NILM-Algorithmen implementiert, um die intensiven Verbraucher zu disaggregieren und die am besten geeigneten Methoden für unseren Datensatz zu ermitteln. Auf Basis der Literaturrecherche wurden Ansätze auf Basis des maschinellen Lernens ausgewählt, da diese als besonders vielversprechend gelten. Zu den ausgewählten Methoden gehören die CNN-Architektur auf Basis des Seq2Point-Lernens, wie sie in [7] beschrieben wurde, sowie der EnerGAN-Algorithmus von [9]. Beide Ansätze haben in der Literatur für Datensätze mit niedriger zeitlicher Auflösung gute Ergebnisse gezeigt. Zudem wurde eine CNN-Architektur auf Grundlage von Heat Maps, inspiriert durch [18], implementiert. Eine Auflösung von 15-Min wurde für alle Daten angenommen. Die angewandten Algorithmen wurden mittels Daten von 26 Wochen trainiert und in einem Zeitraum von 11 Wochen getestet.

3 Bewertung der Ergebnisse

Für die Bewertung der Algorithmen werden für ein Zeitfenster von 24 Stunden die Metriken E_{ACC} und MR, welche in (1) und (2) definiert sind, verwendet. Die ausgewählten Haushalte (H1, H2, H3) verfügen über eine unterschiedliche Anzahl von Intensivverbrauchern sowie über ein unterschiedliches Verbraucherverhalten.

3.1 Nicht-flexible Anteile des Stromverbrauchs

Die tatsächliche Grundlast lässt sich während der Urlaubszeiten zuverlässig bestimmen, da der Verbrauch in dieser Phase ausschließlich aus der Grundlast besteht. Deshalb

dienen die Verbrauchsdaten aus diesen Zeiträumen als Referenz zur Bewertung der Genauigkeit des Algorithmus. Bild 1 zeigt den mittleren täglichen Stromverbrauch sowie die berechnete mittlere Tagesgrundlast für die drei Häuser während den Urlaubsphasen in 2023. Es ist ersichtlich, dass der Algorithmus in der Lage ist, die Tagesgrundlast mit sehr hoher Genauigkeit zu berechnen.




Bild 1 Berechnete mittlere Tagesgrundlast und mittlerer Tagesverbrauch während der Urlaubszeiten

Zusätzlich wurden die stromintensivsten Geräte aus der Grundlast mit den ausgewählten Algorithmen disaggregiert. Tabelle 2 und Tabelle 3 zeigen die täglichen E_{ACC} bzw. MR-Werte. Alle drei Algorithmen haben Ergebnisse mit sehr hoher Genauigkeit geliefert, wobei Seq2Point über alle Geräte hinweg gleichbleibend Ergebnisse mit der höchsten Übereinstimmungsrate liefert, was auch in Übereinstimmung mit der Literatur ist [6][7]. Obwohl die Machine-Learning-Algorithmen Trainingsdaten benötigen, besteht die Möglichkeit, vortrainierte Algorithmen auf ungesicherte Daten anzuwenden. Es wurde gezeigt, dass der Seq2Point-Algorithmus sehr gut domänenübergreifend übertragbar ist [19].

	H1		H2		H3	
Gerät	KS	KS1	KS2	KS1	KS2	GT
IMG-NILM	0,94	0,93	0,88	0,95	0,92	0,94
Seq2Point	0,94	0,96	0,91	0,95	0,93	0,96
EnerGAN	0,93	0,93	0,90	0,95	0,91	0,97

Tabelle 2 Tägliche E_{ACC} für die Kühl- und Gefriergeräte in den drei Haushalten. KS: Kühlschrank, GT: Gefriertruhe

	H1		H2		H3	
Gerät	KS	KS1	KS2	KS1	KS2	GT
IMG-NILM	0,90	0,87	0,78	0,91	0,84	0,89
Seq2Point	0,89	0,92	0,82	0,91	0,86	0,93
EnerGAN	0,86	0,86	0,80	0,90	0,83	0,93

Tabelle 3 Tägliche Match Rate MR für die Kühl- und Gefriergeräte in den drei Haushalten. KS: Kühlschrank, GT: Gefriertruhe




Bild 2 Disaggregationsergebnisse für die Kühl- und Gefriergeräte in den Haushalten

Wie oben dargestellt, lässt sich der nicht-flexible Anteil des Stromverbrauchs in einem Haushalt mit hoher Genauigkeit bestimmen – sowohl pauschal als gesamte Grundlast des Hauses als auch anteilig für periodisch laufende Geräte wie Kühl- und Gefrierschränke.

3.2 Flexibler Anteil des Verbrauchs

Nachfolgend werden die Ergebnisse der Disaggregation der übrigen intensiv untersuchten Haushaltsgeräte präsentiert. Dabei stehen WM für Waschmaschine, GS für Geschirrspüler und WT für Wäschetrockner. Im Gegensatz zu Kühl- und Gefrierschränken werden diese Geräte seltener genutzt und oft nur wenige Male pro Woche betrieben. Die geringe Häufigkeit der Nutzung stellt in Kombination mit der niedrigen Auflösung der Messdaten eine Herausforderung für die Algorithmen dar, da nicht genügend Betriebszyklen zur Verfügung stehen, um ein effektives Lernen und eine präzise Disaggregation zu ermöglichen. Tabelle 4 und Tabelle 5 zeigen die Ergebnisse der Disaggregation für die flexibel einsetzbaren Haushaltsverbraucher. EnerGAN lieferte für H1 und H2 keine zufriedenstellenden Ergebnisse. Es muss hier betont werden, dass nur E_{ACC} nicht ausreichend ist, um die Ergebnisse der Algorithmen zu bewerten. Im Fall von EnerGAN können die E_{ACC} -Werte von ca. 0,5 in diesem Fall irreführend sein. Die Geräte waren die meiste Zeit ausgeschaltet und meistens max. einmal pro Tag in Betrieb. Da der Algorithmus nahezu null Ergebnisse geliefert hat bzw. den Verbrauch deutlich unterschätzt hat (Bild 3), spiegelt der E_{ACC} -Wert eher die zufällige Übereinstimmung mit diesem Grundwert wider, anstatt die Fähigkeit des Algorithmus, den Betrieb des Geräts während seiner kurzen aktiven Phasen zu erkennen. Daher sind zusätzliche Metriken wie die Match-Rate notwendig, um die

Leistung des Algorithmus realistisch zu bewerten. Im Gegensatz dazu lieferten Seq2Point und IMG-NILM deutlich bessere Ergebnisse, wobei Seq2Point stetig die besten Resultate erzielte. Im Haus 1 konnte der Geschirrspüler mit einer besonders hohen Energiegenauigkeit und Übereinstimmungsrate identifiziert werden. Allgemein zeichnet sich Haus 1 durch einen niedrigen Energieverbrauch und nur wenige Haushaltsgeräte mit hoher Leistungsaufnahme aus. Dadurch ist in diesem Haushalt weniger Rauschen im Stromverbrauch vorhanden, was die Disaggregation erleichtert. Die Waschmaschine in diesem Haushalt wurde jedoch nur selten betrieben. Aufgrund der wenigen Betriebsphasen konnten die Algorithmen hier keine zufriedenstellende Leistung erbringen.

	H1		H2		H3		
Gerät	GS	WM	WT	WM	GS	WT	WM
IMG-NILM	0,42	0,10	0,69	0,64	0,60	0,32	0,59
Seq2Point	0,81	0,48	0,64	0,74	0,63	0,72	0,63
EnerGAN	0,50	0,49	0,52	0,52	0,60	0,69	0,58

Tabelle 4 Tägliche E_{ACC} Werte für die kurzzeitig intensiven Stromverbraucher in den Haushalten H1, H2 und H3

	H1		H2		H3		
Gerät	GS	WM	WT	WM	GS	WT	WM
IMG-NILM	0,16	0,12	0,48	0,49	0,49	0,36	0,49
Seq2Point	0,72	0,07	0,37	0,60	0,47	0,53	0,49
EnerGAN	0	0	0,07	0,05	0,41	0,46	0,28

Tabelle 5 Tägliche MR Werte für die kurzzeitig intensiven Stromverbraucher in den Haushalten H1, H2 und H3




Bild 3 Disaggregationsergebnisse für die kurzzeitig intensiven Stromverbraucher in H1, H2 und H3 Haushalten

Der Algorithmus auf Basis des Seq2Point Lernens, der die besten Ergebnisse geliefert hat, konnte über alle Haushalte und Geräte hinweg eine Energieverbrauchsgenauigkeit von 66,4% erreichen. Die Ergebnisse bestätigen die Erkenntnisse aus der Literatur für Daten mit sehr niedriger zeitlicher Auflösung (Tabelle 1). Um die Disaggregationsgenauigkeit zur Abschätzung des flexiblen Anteils zu erhöhen, wird im nächsten Schritt der flexible Verbrauch der einzelnen Geräte aufsummiert. Es wird erwartet, dass das Zusammenführen des Verbrauchs mehrerer Haushaltsgeräte insbesondere bei Daten mit niedriger zeitlicher Auflösung zuverlässigere Ergebnisse liefern kann, da individuelle Gerätemuster oft schwer und daher unzuverlässig zu erkennen sind. Die Ergebnisse der Disaggregation für jeden Haushalt und die jeweilige Methode sind für die kumulierten Geräte in Tabelle 6 und Bild 4 dargestellt. Die Erwartungen werden bestätigt. Eine deutliche Erhöhung der Disaggregationsgenauigkeit ist in allen drei Haushalten ersichtlich.

Für die Haushalte H2 und H3 konnte eine deutliche Verbesserung der Ergebnisse über alle Algorithmen hinweg festgestellt werden (Tabelle 6). Die höchste Energieverbrauchsgenauigkeit vom 88% für H3 liefert auch hier der Seq2Point Algorithmus. Auch in H1 hat das Zusammen-

fassen des Verbrauchs von Waschmaschine und Spülmaschine die Gesamtgenauigkeit verbessert. Die Energieverbrauchsgenauigkeit für die Spülmaschine war jedoch vor dem Zusammenfügen deutlich höher. Der Grund dafür liegt darin, dass die Waschmaschine in H1 ein stark abweichendes Lastprofil im Vergleich zur Spülmaschine aufweist, was das Lernen des Algorithmus erschwert. Aus diesem Grund hat EnerGAN auch hier die Energie deutlich unterschätzt (Bild 4). Über alle Haushalte und Geräte hinweg war der Algorithmus in der Lage, eine Energieverbrauchsgenauigkeit von 79,3% erreichen, was eine deutliche Verbesserung im Vergleich zu den vorherigen Ergebnissen darstellt.

	H1		H2		H3	
	GS+WM		WM+WT		GS+WM+WT	
	EACC	MR	EACC	MR	EACC	MR
IMG-NILM	0,57	0,29	0,61	0,46	0,67	0,58
Seq2Point	0,74	0,54	0,76	0,58	0,88	0,79
EnerGAN	0,67	0,44	0,70	0,43	0,85	0,72

Tabelle 6 Tägliche EACC und MR Werte für die kumulierten intensiven Stromverbraucher in H1, H2 und H3




Bild 4 Disaggregationsergebnisse für den gesamten Verbrauch der kumulierten intensiven Stromverbraucher in H1, H2 und H3

Auf Basis der oben genannten Ergebnisse konnte das Flexibilisierungspotential über einen Zeitraum von 11 Wochen mit hoher Genauigkeit abgeschätzt werden. Es ist ersichtlich, dass die Haushalte ein sehr unterschiedliches Flexibilisierungspotential aufweisen. Dieses beträgt im H1 6,9 %, im H2 15,8 % und im H3 39,4 % des gesamten Haushaltsverbrauchs (Bild 4). Es muss hierbei betont werden, dass der Backofen und Herd wegen der schwierigen Umsetzung eines Messsystems nicht erfasst wurden.

4 Fazit

In diesem Beitrag wurde das Flexibilisierungspotential des Haushaltsstromverbrauchs in drei Haushalten mit unterschiedlichem Verbrauchsmuster abgeschätzt. Zu diesem Zweck wurde der Verbrauch in einen flexiblen und einen nicht flexiblen Anteil unterteilt. Zur Erkennung unterschiedlicher Haushaltsgeräte wurden zahlreiche Disaggregationsalgorithmen (Seq2Point, IMG-NILM, EnerGAN) eingesetzt. Es wurde gezeigt, dass der nicht-flexible Anteil des Haushaltsstromverbrauchs sich mit hoher Genauigkeit bestimmen lässt – sowohl pauschal als gesamte Grundlast des Hauses als auch anteilig für periodisch laufende Geräte wie Kühl- und Gefrierschränke. Der Algorithmus auf Basis des Seq2Point-Learnings lieferte für alle Haushalte die besten Ergebnisse. Die Abschätzung des flexiblen Anteils war schwieriger, da Geräte wie Waschmaschinen und Geschirrspüler aufgrund ihrer selteneren Nutzung und niedrigen zeitlichen Datenauflösung schwierig zu analysieren waren. Das Zusammenführen der Verbräuche mehrerer Geräte führte zu einer deutlichen Verbesserung der Ergebnisse. Es wurde gezeigt, dass das Flexibilisierungspotential, entweder durch das Rausfiltern des nicht-flexiblen Anteils vom Gesamtverbrauch oder durch die direkte Disaggregation der flexiblen Haushaltsverbraucher, mit hoher Genauigkeit abgeschätzt werden kann.

Die abgeschätzten verschiebbaren und daher flexiblen Verbrauchsanteile sind sehr individuell und variieren für die drei beispielhaft ausgewählten Haushalte zwischen 6,9% für Haushalt H1 mit dem niedrigsten absoluten Verbrauch und einem sparsameren Verhalten bis zu 39,4% bei Haushalt H3 mit hohem Verbrauch und häufig verwendeten Haushaltsgeräten.

Danksagung

Die Arbeit entstand im Rahmen des Projektes „Erhöhung der Verbraucherpartizipation an der Energiewende durch KI-Technologien und datenbasierte Mehrwertdienste – EVEKT“, das vom Bundesministerium für Wirtschaft und Klimaschutz (Förderschwerpunkt: Energiewende und Gesellschaft, Förderkennzeichen: 03EI5234A) gefördert wird.

5 Literatur

[1] P. A. Schirmer, I. Mporas: "Non-Intrusive Load Monitoring: A Review," IEEE Transactions on Smart Grid, vol. 14, no. 1, pp. 769-784, 2023, doi: 10.1109/TSG.2022.3189598.

- [2] L. Pereira, N. Nunes: "Performance evaluation in non-intrusive load monitoring: Datasets, metrics, and tools—A review," WIREs Data Mining and Knowledge Discovery, vol. 8, no. 6, May 2018, doi: 10.1002/widm.1265.
- [3] B. Zhao, L. Stankovic, V. Stankovic: "Electricity usage profile disaggregation of hourly smart meter data", 2018 Poster session presented at 4th International Workshop on Non-Intrusive Load Monitoring, Austin, USA
- [4] K. Basu, V. Debusschere, S. Bacha, U. Maulik, S. Bondyopadhyay; "Nonintrusive Load Monitoring: A Temporal Multilabel Classification Approach," IEEE Transactions on Industrial Informatics, vol. 11, no. 1, pp. 262-270, 2015, doi: 10.1109/TII.2014.2361288.
- [5] L. Massidda, M. Marrocu, S. Manca: "Non-intrusive load disaggregation by convolutional neural network and multilabel classification," Appl. Sci., vol. 10, no. 4, p. 1454, 2020, doi: 10.3390/app10041454
- [6] B. Zhao, M. Ye, L. Stankovic, V. Stankovic: "Non-intrusive load disaggregation solutions for very low-rate smart meter data", Applied Energy, v. 268, 2020, doi: 10.1016/j.apenergy.2020.114949
- [7] C. Zhang, M. Zhong, Z. Wang, N. Goddard, C. Sutton, "Sequence-to-point learning with neural networks for nonintrusive load monitoring", The Thirty-Second AAAI Conference on Artificial Intelligence (AAAI-18), 2018
- [8] B. Zhao, L. Stankovic, V. Stankovic: "On a Training-Less Solution for Non-Intrusive Appliance Load Monitoring Using Graph Signal Processing," IEEE Access, vol. 4, pp. 1784-1799, 2016, doi: 10.1109/ACCESS.2016.255746
- [9] M. Kaselimi, A. Voulodimos, E. Protopapadakis, N. Doulamis and A. Doulamis, "EnerGAN: A generative adversarial network for energy disaggregation" ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Barcelona, Spain, 2020, pp. 1578-1582, doi: 10.1109/ICASSP40776.2020.9054342
- [10] A. Majumdar, "Trainingless Energy Disaggregation Without Plug-Level Sensing," in IEEE Transactions on Instrumentation and Measurement, vol. 71, pp. 1-8, 2022, Art no. 2504808, doi: 10.1109/TIM.2022.3152311
- [11] S. Singh and A. Majumdar, "Analysis Co-Sparse Coding for Energy Disaggregation," in IEEE Transactions on Smart Grid, vol. 10, no. 1, pp. 462-470, 2019, doi: 10.1109/TSG.2017.2743763
- [12] A. Miyasawa, Y. Fujimoto and Y. Hayashi, "Energy Disaggregation Based on Smart Metering Data via Semi-Binary Nonnegative Matrix Factorization" in Energy and Buildings 183, 2018, doi: 10.1016/j.enbuild.2018.10.030
- [13] J. Kolter and M. Johnson, "REDD: A Public Data Set for Energy Disaggregation Research." Available: <https://people.csail.mit.edu/matttj/papers/kddsust2011.pdf>

- [14] D. Murray, L. Stankovic, and V. Stankovic, "An electrical load measurements dataset of United Kingdom households from a two-year longitudinal study," *Scientific Data*, vol. 4, no. 1, 2017, doi: 10.1038/sdata.2016.122
- [15] S. Makonin, F. Popowich, L. Bartram, B. Gill and I. V. Bajić, "AMPds: A public dataset for load disaggregation and eco-feedback research," 2013 IEEE Electrical Power & Energy Conference, Halifax, NS, Canada, 2013, pp. 1-6, doi: 10.1109/EPEC.2013.6802949
- [16] J. Kelly and W. Knottenbelt, "The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes," in *Scientific Data*, vol. 2, p. 150007, 2015, doi: 10.1038/sdata.2015.7
- [17] O. Parson et al., "Dataport and NILMTK: A building data set designed for non-intrusive load monitoring," 2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP), Orlando, FL, USA, 2015, pp. 210-214, doi: 10.1109/GlobalSIP.2015.7418187
- [18] Heat Maps J. Edmonds und Z. S. Abdallah, „IMG-NILM: A Deep learning NILM approach using energy heatmaps“, in *Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing*, New York, Association for Computing Machinery, 2023, pp. 1151-1153.
- [19] M. D’Incecco, S. Squartini and M. Zhong: "Transfer Learning for Non-Intrusive Load Monitoring," in *IEEE Transactions on Smart Grid*, vol. 11, no. 2, pp. 1419-1429, 2020, doi: 10.1109/TSG.2019.2938068.



**Product Carbon Footprint
POWEREDGE R350**

Report produced August 2022

At Dell Technologies, we believe in a future where technology drives progress to address some of the biggest environmental challenges we face today. We're working to reduce our impact on the planet throughout our business and products. Reducing the carbon footprint of our products is critical to enabling our customers to achieve their own sustainability goals. Therefore, it is important to understand the application and limitation of this carbon data:

- A **carbon footprint** is the total amount of greenhouse gases released into the atmosphere by a given activity. The larger the footprint the larger the impact on the environment.
- A **product carbon footprint** is a measure of greenhouse gas emissions across the life cycle of a product from the extraction of raw materials, manufacturing, and distribution through to its use and end of life.

To calculate PCFs Dell uses PAIA (*Product Attribute to Impact Algorithm*), a streamlined Life-Cycle Assessment tool developed by [MIT's Materials System Laboratory](#). PAIA takes into consideration important attributes of the product which can be correlated to activities like manufacturing, transportation, etc., to calculate the product's carbon footprint.




Calculating an exact product carbon footprint is very challenging due to the complexity and variability in the data. The same product will have a different carbon footprint depending on myriad variables, including the geographical location of where the device is used, the configuration of the hardware, how long it is used and how it is retired. For this product, the estimated carbon footprint is 674 kg of CO_{2e} at the 5th percentile and 5,080 kg of CO_{2e} at the 95th percentile.

Assumptions for calculating PCF


Product Weight	12.8 kg	Server Type	Rack	Assembly Location	Asia
Product Lifetime	4 years	Use Location	Europe	Energy Demand (Yearly TEC) ¹	928.6 kWh
HDD/SSD Quantity	2	DRAM Capacity	32GB	CPU Quantity	1
Fan Count	4	PSU Count	2	Core Count per CPU	6

ESTIMATED IMPACT BY LIFECYCLE STAGE



Illustrative chart to depict product carbon footprint by geographic location

As depicted in the graph below, the emissions for the manufacturing, transport and end-of-life phases are minor and remain static no matter where the configuration is being used. However, a variety of factors including the geographic location's energy mix and the specific hardware configuration can have a significant impact on the use phase of the product carbon footprint. This makes it difficult to assign a singular value across multiple configurations of a single Dell Technology product that could be used globally.



Dell Technologies strives to provide innovative solutions that protect our planet and people as well as provide enhanced performance so users can consolidate infrastructure to reduce space requirements and power consumption without affecting performance. For more information on our initiatives please visit Dell.com/Sustainability

Disclaimer: This PCF was calculated using the PAIA model, version 1.3.2, copyright by the ICT Benchmarking collaboration, which includes the Massachusetts Institute of Technology's Materials Systems Laboratory and partners. Results shown here are subject to change as the tool is updated. The Use component of the PCF assumes a PUE of 1.0. If your Data Center PUE differs from 1.0, the Use component may be ratiometrically scaled up from a PUE of 1.0.

1 Typical ENERGY STAR power computation used to derive this value. "TEC is the Total Energy Consumption