

Future Energy
Lab

LEITFADEN

KI in Fernwärme

Ein Leitfaden zur erfolgreichen Umsetzung
von KI-Projekten

Impressum

Herausgeber:

Deutsche Energie-Agentur GmbH (dena)
Chausseestraße 128 a
10115 Berlin
Tel: +49 30 66 777-0
Fax: +49 30 66 777-699
E-Mail: info@dena.de
Internet: www.dena.de, www.future-energy-lab.de

Autoren:

Marius Dechand, dena
Lukas Huttny, dena
Hendrik Zimmermann, dena
Sven Rausch, RAUSCH Technology GmbH
Timo Krey, RAUSCH Technology GmbH

Konzeption & Gestaltung:

Heimrich & Hannot GmbH

Bildnachweis:

S. 55 – Stadtwerke Norderstedt

Stand:

10/2024

Alle Rechte sind vorbehalten. Die Nutzung steht unter dem Zustimmungsvorbehalt der dena.

Bitte zitieren als:

Deutsche Energie-Agentur (Hrsg.) (dena, 2024) „KI in Fernwärme: Ein Leitfaden zur erfolgreichen Umsetzung von KI-Projekten“



**Bundesministerium
für Wirtschaft
und Klimaschutz**

Die Veröffentlichung dieser Publikation erfolgt im Auftrag des Bundesministeriums für Wirtschaft und Klimaschutz. Die Deutsche Energie-Agentur GmbH (dena) unterstützt die Bundesregierung in verschiedenen Projekten zur Umsetzung der energie- und klimapolitischen Ziele im Rahmen der Energiewende.

Inhalt

Vorwort	5
Executive Summary	6
1. Hintergrund	9
1.1. Die Bedeutung von Digitalisierung und KI für die Energiewende	10
1.2. Das Projekt „KI in Fernwärme“	11
1.3. Fernwärmenetze	12
1.3.1. Markt und Regulierung	13
1.3.2. Komponenten.....	14
1.4. Künstliche Intelligenz.....	17
1.4.1. Einführung in die Künstliche Intelligenz	17
1.4.2. Definition und Abgrenzung: Was KI ist und wie sie sich von menschlicher Intelligenz unterscheidet	17
1.4.3. Von den Anfängen bis zu den aktuellen Durchbrüchen	18
1.4.4. Teilbereiche der Künstlichen Intelligenz (Circle of AI)	19
1.4.5. Daten und Künstliche Intelligenz	23
1.4.6. Algorithmen und Modellierungsansätze: Überblick über die wichtigsten KI-Algorithmen und ihre Anwendungen.....	23
1.5. Ethik und Verantwortung	26
2. KI-Anwendungsfälle	28
2.1. Methodisches Framework.....	29
2.2. KI-Anwendungsfälle in Wärmenetzen.....	30
2.3. Komplexität und Potenzial der KI-Anwendungsfälle.....	34

3. Projektblaupause	36
3.1. Business Understanding: Zielsetzung definieren und Geschäftsverständnis entwickeln	38
3.2. Data Understanding: Verfügbarkeit von Daten prüfen und Datenexploration	40
3.3. Data Preparation: Datenverarbeitung und ETL-Pipelines	44
3.4. Modeling: Modellierungsmethodologie	46
3.5. Evaluation: Evaluierung des Anwendungsfalls.....	48
3.6. Deployment: Integration der Systeme.....	51
3.7. Laufender Betrieb: Überwachung, Wartung, Aktualisierung	52
4. Herausforderungen bei der Umsetzung von KI-Projekten	53
4.1. Herausforderungen im Projekt „KI in Fernwärme“	54
4.2. Perspektivwechsel: Herausforderungen für die Stadtwerke Norderstedt	56
5. Handlungsempfehlungen	61
Abbildungsverzeichnis	64
Tabellenverzeichnis	64
Literaturverzeichnis	65
Abkürzungen	68
Anhang	70

Vorwort

Die Dekarbonisierung des Wärmesektors ist ein wesentlicher Bestandteil der Energiewende und entscheidend für das Erreichen der Klimaziele in Deutschland. Der Wärmesektor bietet erhebliche CO₂-Einsparpotenziale, die mithilfe innovativer Ansätze und Technologien realisiert werden können. Besonders die Umstellung auf erneuerbare Energien und die Verbesserung der Energieeffizienz können maßgeblich zur Reduktion der Emissionen beitragen. Das Gebäudeenergiegesetz (GEG) in Kombination mit der Kommunalen Wärmeplanung (KWP) weist den Weg für die zukünftige Entwicklung des Wärmesektors. Dabei wird deutlich, dass Fernwärmenetze künftig eine noch bedeutendere Rolle einnehmen und dass Deutschland durch die teilweise Elektrifizierung der Wärmeversorgung eine enge Integration mit dem Stromsektor anstrebt. Digitale Technologien sind in diesem immer komplexer werdenden Energiesystem eine wesentliche Voraussetzung, um die Herausforderungen der Energiewende erfolgreich zu meistern, da sie die notwendige Automatisierung von Geräten und Anlagen, Flexibilisierung des Energiesystems und Systemeffizienz erst ermöglichen.

Im Future Energy Lab (FEL) der Deutschen Energie-Agentur (dena) wird seit seiner Gründung 2020 der Einsatz innovativer digitaler Technologien für die Energiewende erprobt. Ein Schwerpunkt liegt dabei seit dem Start des FEL auf dem Thema Künstliche Intelligenz (KI). Im Rahmen des Projekts EnerKI (01/2019–08/2020) wurden neun KI-Anwendungsfelder für die Energiewirtschaft identifiziert und hinsichtlich ihres Beitrags für die integrierte Energiewende und ihres Entwicklungsstands eingeordnet. In der weiterführenden Analyse „Künstliche Intelligenz – vom Hype zur energiewirtschaftlichen Realität“ (08/2022) (dena, 2020) wurde dargestellt, unter welchen Voraussetzungen einzelne Use Cases aus den neun Anwendungsfeldern in der Energiewirtschaft bereits umgesetzt werden und wo noch Handlungsbedarf für verschiedene Akteure zur Förderung des weiteren Einsatzes Künstlicher Intelligenz im Energiesystem besteht. Aufbauend auf diesen Ergebnissen wurden durch eine sehr praxisnahe Herangehensweise im Projekt „Data4Grid“ (01/2021–01/2023) (dena, 2023) konkrete KI-Anwendungsfälle in Stromnetzen vorangetrieben. Dazu haben Netzbetreiber und Start-ups gemeinsam in drei Challenges Prototypen zu den jeweiligen KI-Anwendungsfällen entwickelt. Im Rahmen einer wissenschaftlichen Begleitung wurde aus dieser praxisnahen Herangehensweise ein „Implementierungsleitfaden für den Einsatz von innovativen, datengetriebenen Anwendungen im Stromnetz“ (Fraunhofer IEE, 2022) entwickelt, der im August 2022 veröffentlicht wurde.

Das Projekt „KI in Fernwärme“ bildet das Pendant zu „Data4Grid“ für Fernwärmenetze. Ziel des Projekts ist, KI-Anwendungsfälle zu identifizieren und deren Einsatz dieser in der Praxis voranzubringen. Dazu haben die Stadtwerke Norderstedt und das Start-up RAUSCH Technology GmbH gemeinsam einen KI-Anwendungsfall prototypisch implementiert und praxisnahe Erfahrungen gesammelt und dokumentiert. Basierend darauf hat die dena gemeinsam mit den Projektpartnern eine Projektblaupause entwickelt, die Fernwärmeversorgungsunternehmen bei der Umsetzung von KI-Projekten unterstützen soll. Die Erkenntnisse des Projekts sowie die Projektblaupause sind in diesem Bericht zusammengefasst. Der Bericht richtet sich an Fernwärmeversorgungsunternehmen, KI-Lösungsanbieter und weitere interessierte Akteure der Energie- und Digitalwirtschaft, der Politik, Wissenschaft und Zivilgesellschaft. Es werden neben den Grundlagen zu Fernwärmenetzen und Künstlicher Intelligenz auch die Herausforderungen eines Fernwärmeversorgungsunternehmens dargestellt. Basierend darauf werden konkrete KI-Anwendungsfälle definiert und deren Potenzial und Komplexität eingeordnet. Schließlich wird den Leserinnen und Lesern die Projektblaupause an die Hand gegeben, die auf den konkreten Erfahrungen aus der prototypischen Implementierung basiert.

An dieser Stelle möchten wir all unseren Projektpartnern einen herzlichen Dank aussprechen. Insbesondere die Stadtwerke Norderstedt sowie die RAUSCH Technology GmbH lieferten mit ihrer fachlichen Expertise konstant hervorragende Arbeitsergebnisse, die von hohem Wert für den Erfolg des Projektes waren. Ein besonderer Dank gilt dem Bundesministerium für Wirtschaft und Klimaschutz für die Finanzierung dieses Projekts.



Hendrik Zimmermann
Teamleiter
Digitale Technologien
Deutsche Energie-Agentur
(dena)



Marius Dechand
Seniorexperte
Digitale Technologien
Deutsche Energie-Agentur
(dena)

Executive Summary

Im Projekt „KI in Fernwärme“ wurden zehn konkrete KI-Anwendungsfälle definiert und nach deren Komplexität und Potenzial bewertet. Obwohl eine allgemeingültige Aussage über das Potenzial der verschiedenen Anwendungsfälle schwer zu treffen ist, da sowohl die Komplexität der Implementierung als auch der konkrete (ökonomische) Nutzen eines Anwendungsfalls stark von den Voraussetzungen beim implementierenden Fernwärmeversorgungsunternehmen (FVU) abhängen, konnten die Optimierung des Wärmeerzeugerbetriebs und die Optimierung von Kundenanlagen mit Wirkung auf die Primärseite in dieser Studie als die „low hanging fruits“ identifiziert werden.

Die Optimierung des Wärmeerzeugerbetriebs wurde in diesem Projekt prototypisch bei einem Stadtwerk implementiert. Dabei wurde deutlich, dass durch eine KI-basierte Wärmelastprognose der Prognosefehler gegenüber herkömmlichen Prognoseverfahren teilweise um bis zu 25 Prozent gesenkt werden kann. Als besonders performant haben sich dabei Long Short-Term Memory Networks (LSTM), ein spezielles Verfahren beim Training von Künstlichen Neuronalen Netzen, erwiesen. Basierend darauf wurde durch eine mathematische (nicht KI-gestützte) Optimierungsfunktion der beste Erzeugermix für den gegebenen Zeitraum erstellt. Bereits die Implementierung eines solchen Prototyps hat gezeigt, dass durch den Einsatz von KI herkömmliche Prozesse und Systeme optimiert werden können.

Bei der Implementierung von KI-Anwendungsfällen ist ein systematisches und prozessorientiertes Vorgehen essenziell. Dies unterscheidet KI-Projekte nicht grundlegend von der Umsetzung anderer Strategien, Strukturen, Systeme oder Prozesse in einer Organisation. Es gibt jedoch einige Besonderheiten, die es wert sind, beleuchtet zu werden. In diesem Projekt wurde in Anlehnung an das Cross-Industry-Standard-Process-for-Data-Mining-Modell (CRISP-DM) (Wirth, 2000) eine Projektblaupause entwickelt und mit konkreten Tipps unterfüttert; abgeleitet aus den Erfahrungen der prototypischen Implementierung.

Aus den gesamten Erfahrungen dieses Projekts lassen sich allgemeingültige Handlungsempfehlungen ableiten. Da sich bei der Umsetzung des Projekts keine wesentlichen gesetzlichen Einschränkungen ergaben, richten sich die Handlungsempfehlungen maßgeblich an FVU und KI-Lösungsanbieter.

Handlungsempfehlungen für Fernwärmeversorgungsunternehmen

- **Aufbau einer umfassenden Datengrundlage (Primär- & Sekundärseite):** Der Aufbau einer umfassenden und zuverlässigen Datengrundlage ist unerlässlich. Diese sollte sowohl Daten direkt aus der Wärmeerzeugung und dem Fernwärmenetz als auch Daten aus den Hausübergabestationen auf der Sekundärseite beinhalten, die fortlaufend erhoben werden, um eine umfassende Datenhistorie aufzubauen. Datengetriebene Anwendungen wie KI-Modelle liefern bessere Ergebnisse, je umfassender und qualitativer die Datengrundlage ist.
- **Entwicklung einer Datenstrategie:** Eine klare Datenstrategie ist entscheidend für den erfolgreichen Einsatz von KI in Fernwärmenetzen. Diese Strategie sollte festlegen, welche Daten gesammelt werden, wie diese Daten erhoben werden und woher sie stammen. Zudem muss definiert werden, wer Eigentümer der Daten ist und wer die Verantwortung für deren Verwaltung trägt. Alle relevanten Akteure sollten in diesen Prozess einbezogen werden, um eine umfassende und nachhaltige Datenstrategie zu gewährleisten. Eine gute Datenstrategie hilft dabei, die digitale Transformation strukturiert umzusetzen und wesentlich mehrwertstiftende Prozesse zu priorisieren.
- **Modernisierung der Erhebung von Netzdaten:** Zur Erhebung von Netzdaten in Fernwärmenetzen sollte frühzeitig in geeignete fernauslesbare Messtechnik investiert werden. Diese Technologien ermöglichen eine effiziente und kostengünstige Sammlung von Netzdaten, was zu einer verbesserten Datenqualität und -verfügbarkeit führt und somit die Grundlage für KI-gestützte Optimierungen bildet.
- **Einsatz von Smart Meter Gateways (SMGW) zur Übertragung von Erzeugungs-, Netz- und Verbrauchsdaten:** Für eine erfolgreiche Sektorenintegration ist die Steuerung von Heizanlagen und die damit ermöglichte Bereitstellung von Flexibilitäten für den Stromsektor von entscheidender Bedeutung. Damit einhergehend sind besondere Sicherheitsanforderungen an das Kommunikationsmodul zu beachten. Außerdem muss eine hohe Interoperabilität mit der bestehenden Messinfrastruktur gewährleistet werden. Durch die gebündelte Übertragung verschiedener Messwerte aus unterschiedlichen Sparten können Synergieeffekte erzielt werden, um die Kosten der Digitalisierung sowohl für Betreiber als auch für Verbraucher möglichst gering zu halten. Diese Anforderungen werden durch das SMGW erfüllt.

- **Modernisierung der Datenbanken:** Bestehende Datenbanksysteme sollten modernisiert und beispielsweise zu leistungsfähigen Data Warehouses oder Datenplattformen weiterentwickelt werden. Diese modernen Datenbanken ermöglichen eine effiziente Speicherung, Verwaltung und Analyse großer Datenmengen, was essenziell für den Einsatz von KI in Fernwärmenetzen ist.
- **Etablierung einheitlicher Datenschnittstellen und -formate:** Einheitliche Datenschnittstellen und -formate (zum Beispiel APIs) sind entscheidend für die Integration verschiedener Systeme und Anwendungen. Durch die Standardisierung wird sichergestellt, dass Daten problemlos zwischen unterschiedlichen Systemen ausgetauscht und von KI-Anwendungen verarbeitet werden können und der Grad an Interoperabilität steigt.
- **Förderung einer positiven Unternehmenskultur in Bezug auf KI:** Um die Akzeptanz und den erfolgreichen Einsatz von KI in Fernwärmenetzen zu fördern, sollte eine positive Unternehmenskultur entwickelt werden. Dies umfasst den Abbau von Skepsis gegenüber KI-Anwendungen durch die Demonstration ihrer positiven Auswirkungen auf die Effizienz und Zuverlässigkeit der Fernwärmenetze. Mitarbeiterinnen und Mitarbeiter sollten über die Vorteile und Möglichkeiten, aber auch die Risiken von KI informiert und in deren Anwendung geschult werden, um eine breite Unterstützung und Motivation zu gewährleisten.
- **Ökonomischen und ökologischen Nutzen priorisieren:** Sensorik muss zu einer Kosten- und/oder Emissionssenkung führen, um ihren Einsatz zu rechtfertigen. Innovationsstreiber müssen Technologien entwickeln, die zunächst auch mit einer limitierten bzw. variierenden Datenbasis umgehen können und basierend darauf einen Mehrwert liefern. Gleichzeitig sollten die Systeme entwicklungsfähig angelegt werden, so dass mit einer besseren Datenlage über die Zeit auch die Anwendungsfälle zunehmen und der Nutzen steigen kann.
- **Europäische und nationale Leitplanken bei der Entwicklung von KI-Lösungen beherzigen:** KI-Lösungsanbieter müssen sich bereits bei der Entwicklung der Algorithmen an den relevanten europäischen und nationalen Rahmenwerken orientieren und beispielsweise die Anforderungen des AI-Acts je nach Risikostufe proaktiv mitdenken oder die Reglementierungen der Datenschutz-Grundverordnung (DSGVO) berücksichtigen.

Die konkreten Herausforderungen bei der Implementierung des prototypischen KI-Anwendungsfalls in diesem Projekt lassen sich in die Einflussphasen der beteiligten Akteure sortieren. Hiermit sollen keine Versäumnisse der Akteure dargestellt werden, sondern vielmehr aufgezeigt werden, wo nicht optimierte Bereiche des etablierten Modus Operandi existieren, welche durch den Einsatz von KI verbessert werden können. Die aufgelisteten Herausforderungen und Erfahrungen beziehen sich auf die Implementierung des KI-Anwendungsfalls in diesem Projekt. Dabei spielen die individuellen Voraussetzungen bei den Stadtwerken Norderstedt, das Know-how und die Ressourcen der RAUSCH Technology GmbH sowie die projektbezogenen Vorgaben und Restriktionen der dena im Rahmen des Projekts „KI in Fernwärme“ eine Rolle. Daher können sich bei anderen KI-Projekten in anderen FVU davon abweichende Herausforderungen ergeben. Die gesammelten Handlungsmöglichkeiten geben dennoch einen sehr wertvollen Einblick in die „unvollkommene“ Realität, der sich Projektteams bei der Umsetzung solcher Projekte tatsächlich gegenübersehen. Im Folgenden sind die wesentlichen Herausforderungen bei der Umsetzung dieses Projekts zusammengefasst und in die Einflussphasen der beteiligten Akteure einsortiert:

Handlungsempfehlungen für KI-Lösungsanbieter

- **Mit offenen Standards arbeiten:** Offene Schnittstellen und Formate gewährleisten eine reibungslose Integration und Interoperabilität verschiedener Systeme und Anwendungen. Dies erleichtert die Migration bestehender Systeme auf neue Technologien und stellt sicher, dass Daten und Dienste nahtlos miteinander kommunizieren können. Offene Standards fördern zudem die Flexibilität und Skalierbarkeit der Lösungen, was für die kontinuierliche Weiterentwicklung und Optimierung der Fernwärmenetze durch KI entscheidend ist.
- **Standardprodukte schaffen:** Die Entwicklung spezifischer, nicht übertragbarer Lösungen sollte, soweit möglich, vermieden werden. Dort, wo es möglich ist, sollten Branchenstandards geschaffen werden. Dadurch können Vendor-Lock-In-Effekte¹ vermieden und die gesamtwirtschaftlichen Kosten der digitalen Transformation gesenkt werden.

Herausforderungen in den Einflussphasen von Fernwärmeversorgungsunternehmen

- Schlechte Verfügbarkeit historischer Daten
- Position der/des Schlechtpunkte/s im Netz unbekannt
- Unzureichende Informationslage zu Anomalien in den Zeitreihen
- Fehlende Informationen zu Direktvermarktern von Strom und den Blockheizkraftwerken (BHKW)

¹ Vendor-Lock-In-Effekt: Abhängigkeit eines Kunden von einem Produkt oder einer Dienstleistung eines Anbieters, weil sich ein Wechsel zu einem anderen Mitbewerber technisch und wirtschaftlich nicht lohnen würde.

- Aufbau und Inbetriebnahme des Datawarehouse sehr aufwändig
- Zu viele Speicherorte von Informationen zum Fernwärmenetz
- Messdatenintervalle der Hausanschlussstationen (HAST) sehr lückenhaft
- Sich ändernde Randbedingungen im Fernwärmenetz
- Fehlende Regelbeschreibung für Heizwerke
- Ökonomischer Wert von Messdaten unbekannt


Herausforderungen an der Schnittstelle der Einflussphären von FVU und KI-Lösungsanbietern

- Extraktion von Daten aus der Prozessleittechnik (PLT) aufwändig
- Probleme beim Export von Daten aus der Prozessleittechnik aufgrund veralteter Technik
- Abbruch der IoT-Plattform-Datenauslesung
- Aufwändiger Bezug von Live-Daten zur Vorhersage des Erzeugerfahrplans des nächsten Tags
- Technische Schwierigkeiten beim Einspielen von Prognosen in die Leittechnik

Herausforderungen in den Einflussphären von KI-Lösungsanbietern

- Beschaffung von Strompreisdaten schwierig
- Kombination historischer Daten mit Live-Daten aufwändig

Anhand dieses Pilotprojekts wird deutlich, dass die Digitalisierung essenziell für die Transformation der Fernwärmenetze hin zur nächsten Generation ist. Bereits heute können erhebliche Mehrwerte durch den Einsatz von KI-Anwendungen erzielt werden. Um zukünftig das volle Potenzial digitaler Technologien auszuschöpfen, müssen bereits jetzt die Weichen dafür gestellt werden. Die Digitalisierung ist nicht nur für die Transformation des Energiesystems notwendig, sondern auch ein strategischer Schritt, um komparative Kosten zu reduzieren und Chancen auf ein „neues Geschäft“ zu eröffnen.





1.

Hintergrund

1.1. Die Bedeutung von Digitalisierung und KI für die Energiewende

Deutschland hat sich gemäß dem Pariser Klimaabkommen dazu verpflichtet, bis 2045 klimaneutral zu werden und entsprechend nicht mehr Treibhausgase zu emittieren, als (beispielsweise durch die Natur und Technologien zur CO₂-Abscheidung) kompensiert werden können. Auf der Seite der Emissionen dieser Gleichung stehen unter anderem die Energieerzeugung und der Energieverbrauch in allen Sektoren. Um dort die Emissionen zu reduzieren, werden im Stromsektor sukzessive mit fossilen Brennstoffen betriebene Großkraftwerke durch dezentrale Erzeugungsanlagen zur Nutzung erneuerbarer Energien ersetzt. Die anderen Sektoren (Verkehr, Industrie, Gebäude, Landwirtschaft) sollen elektrifiziert oder mit anderen geeigneten klimaneutralen Energien (zum Beispiel Wasserstoff, Biogas, Geothermie) betrieben werden. Dies impliziert eine enge Integration aller Sektoren. Insbesondere in Hinblick auf die Elektrifizierung werden große Teile ganzer Sektoren zu neuen Abnehmern des Stromsektors. Gleichzeitig weist die neue Erzeugungsstruktur eine fluktuierende Energieerzeugung auf. Um dieser zu begegnen, müssen Energieerzeugung und -abnahme fortlaufend aufeinander abgestimmt werden, was eine direkte Kommunikation zwischen und Automatisierung von Geräten und Anlagen voraussetzt. An genau dieser Stelle, der Ermöglichung der Dezentralisierung und Flexibilisierung des Energiesystems, ist Digitalisierung unverzichtbar.

Gleichzeitig und nicht weniger wesentlich kann durch die Nutzung digitaler Technologien die (Energie-)Effizienz einzelner Prozesse sowie des Gesamtsystems erhöht und somit Treibhausgasemissionen reduziert werden. Prominente Beispiele hierfür sind intelligente Steuerungssysteme, die auf Basis einer Echtzeitüberwachung oder von Prognosen des Endenergieverbrauchs die Erzeugungsanlagen und Verbraucher steuern können, um Lastspitzen zu glätten, vorzugsweise lokal erzeugte Energie zu nutzen oder Energiespeicher vorausschauend und effizient in das System zu integrieren. Die Digitalisierung ist zum einen also **Möglichmacherin** der Energiewende, indem erneuerbare Energien überhaupt erst flächendeckend eingesetzt werden können, zum anderen aber auch **Treiberin** der Energiewende, indem die Energieeffizienz erhöht und somit der zu ersetzende Primärenergiebedarf reduziert wird.

Methoden der Künstlichen Intelligenz stellen dabei „Werkzeuge“ der Digitalisierung dar, um in großen Datenmengen Muster zu erkennen und basierend darauf Wahrscheinlichkeiten potenzieller Ergebnisse komplexer und multivariater Situationen vorherzusagen (WEF, 2021). Diese Fähigkeit kann in sämtlichen Bereichen der Energieversorgung, von der Er-

zeugung über Netze, Handel und Vertrieb bis hin zu Verbrauch und Produktion, eingesetzt werden (dena, 2020; BDEW, 2020). Insbesondere im Bereich der Prognosen, seien es Verbrauchsmuster oder prädiktive Wartung, stellen KI-basierte Verfahren einen bereits mehrfach erwiesenen Mehrwert dar (Finkenrath, 2021; Shin, 2021). Dabei sind jedoch auch die teilweise hohen Energiebedarfe zum Training der KI-Modelle mit einzukalkulieren (dena, 2023). Diese können durch innovative Verfahren wie beispielsweise verbesserte Modellübertragungen beim „föderierten Lernen“, einem neuartigen Trainingsprozess von KI-Modellen, oder innovative Hardwarearchitekturen bei spezialisierten Rechenbeschleunigern substanziell gesenkt werden (dena, 2024). Eine wesentliche Herausforderung, die sich auch in diesem Pilotprojekt gezeigt hat (vgl. Kapitel 4. Herausforderungen bei der Umsetzung von KI-Projekten), ist die Bereitstellung von Daten zum Training der KI-Modelle. Historisch gewachsen, liegen Daten oft sehr unstrukturiert und wenig standardisiert vor. Es gibt meist keine einheitlichen Schnittstellen und Möglichkeiten für einen automatisierten Datenaustausch. Auch sind häufig keine klaren Verantwortlichkeiten oder Ansprechpersonen für das Datenmanagement definiert. Die Bereitstellung von Daten wird so bei jedem Projekt erneut zu einer sehr zeitintensiven Aufgabe. Perspektivisch sollen hierfür föderierte Datenräume (beispielsweise Gaia-X, IDS oder dena-ENDA) Abhilfe schaffen, die einen vertrauensvollen und einfachen Datenaustausch unter Einhaltung der Datensicherheit und Datensouveränität mithilfe bestehender Standards, Technologien und Governance-Modelle ermöglichen (dena, 2024).

Es wird deutlich, dass die Dateninfrastruktur, Daten-Governance und Datenanalyse eng miteinander verwoben sind. Diese Elemente müssen simultan weiter vorangetrieben werden, damit durch die Digitalisierung das Energiesystem transformiert wird und Deutschland die gesetzten Klimaziele erreichen kann.

1.2. Das Projekt „KI in Fernwärme“

Der Wärmesektor macht in Deutschland etwas mehr als die Hälfte des Endenergieverbrauchs aus. Davon entfallen etwa 10 Prozent auf die Bereitstellung von Fernwärme. Diese wird derzeit hauptsächlich durch den Einsatz fossiler Brennstoffe erzeugt, wobei Erdgas der Hauptenergieträger ist. Die Dekarbonisierung der Fernwärme ist ein wichtiger Schritt zur Erreichung der Klimaziele im Rahmen der Energiewende. Diesen zu gehen erfordert eine umfassende Digitalisierung sowohl technischer als auch betrieblicher Ebenen, um eine intelligente Steuerung und Integration erneuerbarer Energiequellen zu ermöglichen.

Im Projekt „KI in Fernwärme“ (09/2021-08/2024) hat die dena den Einsatz verschiedener KI-Anwendungsfälle für den Betrieb und die Optimierung von Fernwärmenetzen in Deutschland evaluiert. Dazu wurde gemeinsam mit dem KI-Lösungsanbieter RAUSCH Technology GmbH ein prototypischer KI-Anwendungsfall zur Optimierung des Fernwärmenetzes der Stadtwerke Norderstedt implementiert. Durch das Wärmeplanungsgesetz sind FVU verpflichtet, bis 2026 einen Transformationsplan aufzustellen. Darin soll dargestellt werden, wie das beschriebene Fernwärmenetz spätestens ab 2045 klimaneutral betrieben werden kann. Wesentliche Bestandteile dessen sind eine IST-Analyse und daraus abgeleitete Szenarien zum Umbau beziehungsweise zur Transformation des Fernwärmenetzes. Insbesondere bei diesem Arbeitsschritt sehen die Stadtwerke Norderstedt den Bedarf für eine KI-basierte Wärmelastprognose, mithilfe derer präzisere Szenarien erstellt werden können.

Nach den dargelegten Hintergrundinformationen zum Projekt klärt der vorliegende Bericht im Kapitel 1.3. Fernwärmenetze zunächst über den Fernwärmemarkt auf und gibt einen regulatorischen Überblick zum Status quo. Anschließend werden in Kapitel 1.4. Künstliche Intelligenz wesentliche Elemente der Künstlichen Intelligenz erläutert. Kapitel 1.5. Ethik und Verantwortung gibt im Anschluss einen Überblick über aktuelle (internationale) ethische Leitlinien für die Entwicklung und den verantwortungsvollen Umgang mit KI.


Neben der Pilotierung eines prototypischen KI-Anwendungsfalls zur Optimierung des Wärmeerzeugerbetriebs wurde auch der Austausch mit der Branche gesucht. In der nichtrepräsentativen Umfrage „Künstliche Intelligenz in der Fernwärmeversorgung“ (06/2023) wurden FVU zum Stand der Digitalisierung befragt. Die Umfrage war unterteilt in Fragen zur Dateninfrastruktur und zur Digitalisierungsstrategie. Somit konnte unter anderem festgestellt werden, welche Voraussetzungen bei den befragten Unternehmen für KI-Projekte vorherrschen, in welchen Bereichen sie Verbesserungspotenziale sehen und wie hoch die Bereitschaft für Investitionen in Digitalisierungsprojekte grundsätzlich ist. Die Ergebnisse dieser Umfrage, insbesondere zu den Verbesserungspotenzialen, wurden in einem Expertenworkshop präzisiert und quantifiziert. Dazu

wurden ca. 30 Expertinnen und Experten in einem ausgeglichenen Verhältnis aus KI-Lösungsanbietern, FVU, Forschung und Verbänden eingeladen. Gemeinsam wurden zehn KI-Anwendungsfälle definiert und nach deren Potenzial und Komplexität bewertet. Die Methodik sowie die Ergebnisse des Workshops sind in Kapitel 2. KI-Anwendungsfälle beschrieben.

Der prototypisch umgesetzte KI-Anwendungsfall für die Stadtwerke Norderstedt, die KI-basierte Wärmelastprognose, ist in der Lage, auf Basis von Erzeugungs-, Netz- und Wetterdaten die Wärmelast des Fernwärmenetzes der nächsten 24 Stunden zu prognostizieren. Dabei wurde die **durchschnittliche Fehlerrate** der Prognose gegenüber dem bisherigen Prognoseverfahren **um bis zu 25 Prozent gesenkt**. Darauf aufbauend wurde eine mathematische Optimierung aufgestellt, mit deren Hilfe der zu jedem Zeitpunkt kostengünstigste Erzeugermix ermittelt wird. So konnte die präzisere Prognose der Wärmelast dazu verwendet werden, die Betriebskosten der Wärmeerzeugungsanlagen für die nächsten 24 Stunden zu optimieren. Besonders effektiv ist dieser Ansatz bei einer heterogenen Erzeugerstruktur, die sowohl Power-to-Heat-Anlagen wie zum Beispiel Wärmepumpen als auch Kraft-Wärme-Kopplungsanlagen (KWK-Anlagen) zur simultanen Erzeugung von Strom und Wärme beinhaltet. Detaillierte Informationen zu den getesteten KI-Modellen, den verwendeten Daten und deren Korrelation sowie der mathematischen Optimierungsfunktion befinden sich in Kapitel 3. Projektblaupause. In diesem Kapitel wird außerdem auf Basis der Erfahrungen aus der Pilotierung und einschlägiger wissenschaftlicher Literatur eine Schritt-für-Schritt-Anleitung zur Durchführung von KI-Projekten bei FVU gegeben und mit praxisnahen Tipps zu den jeweiligen Schritten unterfüttert.

Bei der Implementierung des KI-Anwendungsfalls ist das Projektteam auf verschiedene projektspezifische Herausforderungen gestoßen. Diese entstanden hauptsächlich aus den individuellen Voraussetzungen der Projektbeteiligten. Eine Sammlung dieser Herausforderungen befindet sich in Kapitel 4. Herausforderungen bei der Umsetzung von KI-Projekten. Um noch genauer die Perspektive eines FVUs zu beleuchten, gibt zusätzlich ein Experteninterview mit dem Fachgebietsleiter Tim Storbeck der Stadtwerke Norderstedt Aufschluss darüber, welche Schwierigkeiten in einem KI-Projekt Vorschlag: zu erwarten sind.

Abschließend werden in Kapitel 5. Handlungsempfehlungen die wesentlichen Erkenntnisse der einzelnen Arbeitsschritte des Projekts in konkrete Handlungsempfehlungen übertragen.



1.3. Fernwärmenetze

Fernwärmenetze sind Infrastruktursysteme zur zentralen Bereitstellung und Verteilung von Wärmeenergie an mehrere Endverbraucher. Sie transportieren heißes Wasser oder Dampf von einer oder mehreren zentralen Erzeugungsanlagen, wie zum Beispiel Heizkraftwerken oder industriellen Abwärmquellen, über ein Rohrleitungssystem zu Wohn-, Gewerbe- und Industriegebäuden. Im Vergleich zu dezentralen Einzelheizungen bieten sie den Vorteil, größere und effizientere Anlagen zu nutzen, die bessere Wirkungsgrade aufweisen. Zudem kann die bei der Stromerzeugung anfallende Abwärme in KWK-Anlagen genutzt werden, wodurch der Brennstoffnutzungsgrad maximiert wird.

Angetrieben durch die Bestrebungen zur Dekarbonisierung des gesamten Energie- und somit auch Wärmesektors, steht diese Technologie vor einer Transformation. Fossile Brennstoffe müssen vermieden und durch regenerative Energiequellen ersetzt werden. Dazu zählen neben den „traditionellen“ erneuerbaren Energien (Solarthermie, Geothermie) auch als erneuerbar klassifizierte Energiequellen (unvermeidbare Abwärme), erneuerbare Brennstoffe (Biomasse, Biogas) zum Weiterbetrieb der effizienten KWK-Anlagen und Grünstrom in Power-to-Heat Anlagen wie beispielsweise Wärmepumpen. Einige dieser Energiequellen können nur aufgrund des weitverzweigten Rohrleitungssystems genutzt werden. Industrielle Abwärme ist beispielsweise eine ortsgebundene Energiequelle, die von einem Fernwärmenetz „abgeholt“ werden kann. Dadurch verändern sich die Anforderungen an Fernwärmenetze maßgeblich. Wärme wird nicht mehr nur zentral erzeugt und an die Endverbraucher verteilt, sondern auch dezentral an verschiedenen Stellen eingespeist. Die Implikationen für die Netzplanung sind umfangreich. Mehr dazu in Kapitel 4. Herausforderungen bei der Umsetzung von KI-Projekten.

Wärmenetze stehen nicht das erste Mal vor einer Transformation. Die meisten in Deutschland betriebenen Netze können der dritten Generation zugeordnet werden.

Diese sind im Wesentlichen durch vorgedämmte Leitungen, eine Temperatur unter 100 Grad Celsius und den Einsatz von Industrieabwärme sowie Biomasse-KWKs charakterisiert. Im Gegensatz dazu lieferten Fernwärmenetze der ersten beiden Generationen die Wärme mittels Dampfsystemen und Heißwasser und waren mit einer Temperatur von 100–200 Grad Celsius im Netz sehr ineffizient. Es sind bereits Fernwärmenetze der vierten und fünften Generation in Betrieb. In diesen Netzen wird eine optimale Integration unterschiedlicher Energiequellen angestrebt. Es werden hier keine fossilen Brennstoffe mehr verwendet, sondern vermehrt erneuerbare Quellen wie Geothermie- und Solaranlagen oder Abwärme aus Rechenzentren genutzt. Mit einer maximalen Temperatur von 70 Grad Celsius weisen diese Netze einen sehr geringen Energiebedarf auf und sorgen für eine nahezu verlustfreie Wärme- und Kälteversorgung. Als maßgebliche Unterscheidungskriterien gelten Netztemperatur, Energieeffizienz, Energiequellen, Baustoffe und -methoden (Lund, 2021).

Es wird deutlich, dass Fernwärmenetze der vierten und fünften Generation unter anderem durch Dezentralisierung und Kleinteiligkeit der Erzeugung stark an Komplexität zunehmen. Ein weiteres zentrales Merkmal zukünftiger Fernwärmenetze ist die Integration des Stromsektors. Beispiele hierfür sind die Kraft-Wärme-Kopplung und Wärmepumpen. Durch KWK-Anlagen werden sowohl Strom als auch Wärme erzeugt. Diese können stromnetzdienlich eingesetzt werden, um dann Strom (und Wärme) zu erzeugen, wenn gerade eine Unterversorgung durch erneuerbare Energie herrscht. Andersherum können Wärmepumpen dann zur Bereitstellung von Wärme genutzt werden, wenn es einen Überschuss an durch erneuerbare Energien erzeugten Strom gibt. Diese Art der Integration trägt nicht nur zur Steigerung der Energieeffizienz bei, sondern kann auch zur Flexibilisierung des Stromnetzes beitragen, indem sie Spitzenlasten ausgleicht und die Integration von erneuerbaren Energien unterstützt.

1.3.1. Markt und Regulierung

Zahlen zum Markt aktuell

Der generelle Primärenergieverbrauch in Deutschland nimmt schon seit einigen Jahren ab und betrug 2023 etwa 10.735 Petajoule, also ca. 3.000 Milliarden Kilowattstunden. Gründe dafür sind der Ausbau an erneuerbaren Energien sowie Effizienzsteigerungen bei der Ausnutzung bisheriger Energieträger. Der Verbrauch von Mineralöl und Gasen macht zusammen ca. 60 Prozent aus, während erneuerbare Träger auf ca. 20 Prozent kommen (Umweltbundesamt, 2024).

Der Endenergieverbrauch, also die aus Primärenergieträgern durch Umwandlung gewonnene Energie, ist nur geringfügig gesunken. Bei gleichzeitigen Effizienzsteigerungen und Einsparungen sind Wirtschaftswachstum und Konsumsteigerungen für diese Entwicklung verantwortlich. Mit Blick auf die Sektoren im Jahr 2023 wird klar, dass bei der Industrie, den privaten Haushalten und in Gewerbe, Handel und Dienstleistungen die Wärmeenergie den größten Anteil am Verbrauch ausmacht. Lediglich der Verkehrssektor nutzt fast überwiegend mechanische Energie. Wärme hat mit über 50 Prozent den größten Anteil am Endenergieverbrauch. Ein Zehntel des Wärmebedarfs wird durch Fernwärme gedeckt (Umweltbundesamt, 2024).

Die Wärmeerzeugung für die Fernwärmenetze in Deutschland erfolgt zu ca. drei Vierteln in KWK-Anlagen und ansonsten in Heizkraftwerken. Die Bereitstellung erfolgt überwiegend durch fossile Gase, Stein- und Braunkohle sowie fossile Öle. Die Erzeugung aus erneuerbaren Quellen verzeichnet seit 1990 einen stetigen Anstieg und lag im Jahr 2023 bei einem Anteil von 18,8 Prozent. Hinsichtlich der Energieträger dominiert die Biomasse mit zwei Dritteln der gesamten erneuerbaren Energiebereitstellung. Während sich die Wärmenutzung aus Solarthermie vor allem witterungsbedingt verringert hat, ist ein bedeutender Anstieg der Nutzung von Geothermie und Umweltwärme zu beobachten (Umweltbundesamt, 2024).

In Deutschland gibt es etwa 3.800 Fernwärmenetze. Von ca. 43 Millionen Wohnungen werden etwa 6 Millionen durch Fernwärme versorgt (AGFW, 2023). Die Netzlänge ist in den letzten Jahren stetig gewachsen und beträgt 2023 in Deutschland ca. 36.000 km (BDEW, 2024). In Zeiten mit geringerem Wärmebedarf werden Wärmespeicher genutzt. Auch diese Kapazität im Netz steigt: Der Energieeffizienzverband für Wärme, Kälte und KWK e. V. spricht im Jahr 2021 von einem Zuwachs von 22,5 GWh auf 30,9 GWh.

Eigentumsverhältnisse

In Deutschland befinden sich FVU mit einer Leistung von mehr als 25 MWth überwiegend in öffentlicher Hand. Häufig handelt es sich um eine Sparte der Stadtwerke, die sich ganz oder teilweise in kommunalem Besitz befinden. Eine Statistik des Umweltbundesamtes aus 2022 stellt die Eigentumsverhältnisse von zehn großen FVU in Deutschland dar. Daraus geht hervor, dass bei vier der Unternehmen die jeweiligen Städte die allei-

nigen Gesellschafter sind (Ortner, 2022). Seit dem Rückkauf des Hamburger Fernwärmenetzes durch die Stadt Hamburg im Jahr 2019 sind es außerdem Leipzig, München und Flensburg. Als fünfte Stadt reihte sich Berlin im Dezember 2023 ein, als die Hauptstadt das etwa 2.000 km lange Fernwärmenetz des schwedischen Energieversorgers Vattenfall zurückkaufte.

Drittzugang

Anders als beim Stromsektor gibt es im Fernwärmemarkt kein „Unbundling“. Im Stromsektor müssen die Stromerzeugung und -verteilung von unterschiedlichen Unternehmen geleistet werden. Im Wärmesektor wird die Wärme meist von demselben Unternehmen erzeugt und verteilt. Einen Drittzugang zu den Fernwärmenetzen in Deutschland gibt es bislang nur in geringem Umfang. Dieser ergibt sich meist auf Basis individuell ausgehandelter Verträge zwischen FVU und Drittanbietern. Die Europäische Kommission plant derzeit im Entwurf der Renewable Energy Directive (RED) eine Stärkung des Drittzugangs. Diese soll dazu führen, dass die Mitgliedstaaten den Drittanbietern klimaneutraler Wärme den Zugang zu den Fernwärmenetzen erleichtern. Bis 2035 soll der Anteil der erneuerbaren Energien und der unvermeidbaren Abwärme an der Fernwärmeezeugung bei mindestens 50 Prozent liegen.

Die Marktöffnung könnte mögliche Anreize für neue Akteure, neue Investitionen und klimafreundliche Wärmeerzeuger bieten. Gleichzeitig besteht aber auch die Gefahr, dass der zusätzliche regulatorische Aufwand für Behörden und Unternehmen sowie das damit verbundene Binden von Ressourcen dazu führen, dass andere Instrumente zur Dekarbonisierung des Wärmesektors abgelehnt werden. Derzeit wird weiter diskutiert, ob der regulierte Drittzugang einen substanziellen Beitrag zur Dekarbonisierung des Wärmesektors leisten kann. In der neu veröffentlichten Studie der dena im Oktober 2023 „Regulatorische Modelle für eine klimaneutrale Fernwärme in Deutschland“ (dena, 2023) werden dazu vier verschiedene Modelle analysiert.

Durch das Gebäudeenergiegesetz (GEG) sind Gebäudeeigentümer dazu verpflichtet, mindestens 65 Prozent erneuerbare Energien zur Wärmeerzeugung zu verwenden. Der Zeitpunkt der Erreichung hängt von der Veröffentlichung des kommunalen Wärmeplans der jeweiligen Kommune ab, in der das Gebäude liegt. Durch einen Anschluss an Fernwärmenetze haben Gebäudeeigentümer dieses Ziel pauschal erreicht, ohne dass das Fernwärmenetz zwingend einen Anteil von 65 Prozent erneuerbarer Energien im Erzeugungsmix haben muss. Fernwärmenetze sind über das Wärmeplanungsgesetz (WPG) (Gramm, 2024) verpflichtet, bis 2030 30 Prozent erneuerbare Energien und bis 2040 80 Prozent erneuerbare Energien im Erzeugungsmix zu haben. 2045 müssen die Fernwärmenetze vollständig dekarbonisiert sein. FVU müssen bis Ende 2026 einen Fernwärmenetzausbau- und -dekarbonisierungsfahrplan (Transformationsplan) vorlegen.

Mit dem Kraft-Wärme-Kopplungsgesetz (KWKG 2023), dem Erneuerbare-Energien-Gesetz (EEG 2023) sowie dem Bundesprogramm zur Förderung von effizienten Wärmenetzen (BEW), dem Bundesprogramm zur Förderung von energieeffizienten Gebäuden (BEG) und dem Bundesprogramm zur Förderung der Energie- und Ressourceneffizienz in der Wirtschaft (EEW) stellt die Bundesregierung einige Instrumente zur Förderung und Zielerreichung im Fernwärmesektor zur Verfügung. Darüber hinaus regelt das Energieeffizienzgesetz (EnEfG) die Pflichten zur Vermeidung oder Verwendung von Abwärme für Unternehmen und Rechenzentren sowie die Nutzung von Energie- und Umweltmanagementsystemen.


1.3.2. Komponenten

Ein Fernwärmenetz ist ein komplexes System, das Wärme von einer zentralen oder mehreren verteilten Wärmequellen zu verschiedenen Verbrauchern transportiert. Es besteht aus mehreren Schlüsselkomponenten, die sorgfältig geplant, installiert und gewartet werden müssen, um eine effiziente Wärmeversorgung zu gewährleisten. Im Folgenden werden die wesentlichen Komponenten eines Fernwärmenetzes für eine kompakte Übersicht und ein grundlegendes Verständnis beschrieben.



Wärmeerzeugung

Die Wärmeerzeugung ist der erste Schritt im Prozess der Fernwärmeversorgung. Sie umfasst Anlagen wie KWK-Kraftwerke, Heizwerke mit Gaskesseln, (Groß-)Wärmepumpen, Abwärme aus Industrieprozessen und auch Wärmequellen der erneuerbaren Energien wie Solarthermie, Biomasse und Geothermie. Diese vielfältigen und durch die zunehmende Einbindung alternativer/regenerativer Wärmeerzeuger zunehmend komplexeren Einrichtungen erzeugen Wärme, die dann über das Fernwärmenetz zu den Verbrauchern transportiert wird. Je nach Netzgröße und Struktur der Wärmeerzeugung werden an die Heizwerke auch Pufferspeicher angebunden, die Lastspitzen zu den Stoßzeiten auffangen und so für längere Betriebszeiten der Wärmeerzeuger sorgen können sowie dem Betreiber Spielraum in der Betriebsführung ermöglichen.



Fernwärmenetz

Die Wärme wird über ein Netzwerk von Rohrleitungen von den Wärmeerzeugungsanlagen zu den Verbrauchern transportiert. Diese Rohrleitungen sind isoliert, um den Wärmeverlust während des Transports zu minimieren. Das Netzwerk wird in der Regel unterirdisch verlegt und kann je nach Größe des Versorgungsgebiets Hunderte von Kilometern umfassen. Die Wärmeverteilung umfasst zudem Pumpen, Druckhaltung, Ventile und andere Steuerungseinrichtungen, die den Fluss der Wärme durch das Netzwerk regeln. Als Transportmedium wird Wasser verwendet – jedoch existieren auch Dampfnetze.



Fernwärme-Übergabestation

An jedem Verbraucherstandort befindet sich eine Fernwärme-Übergabestation (oder auch Hausanschlussstation (HAST) genannt), die die Verbindung zwischen dem Fernwärmenetz und der internen Hauszentrale herstellt. Sie hat die Aufgabe, die Wärme in der vertragsmäßigen Form (Druck, Temperatur und Volumen) an die Hauszentrale zu übergeben und die abgenommene Wärmemenge zu erfassen. Es gibt zwei Haupttypen von Hausanschlussstationen: „direkte“ und „indirekte“.

- Bei **direkten HAST** erfolgt der Wärmeaustausch direkt zwischen dem Fernwärmekreis und dem Verbraucherkreis, ohne einen separaten Wärmetauscher zur hydraulischen Trennung und ohne erweiterte Regelungstechnik. Dies bedeutet, dass das Wärmeträgermedium des Fernwärmenetzes ins Heizsystem des Gebäudes strömt und dadurch

einen sehr einfachen technischen Aufbau aufweist. Bei einem Rohrleitungsbruch im Gebäude erfolgt die Nachspeisung über das Fernwärmenetz. Da die Nachspeisemengen gering sind, ist eine Detektion seitens des Netzbetreibers sehr selten.

- Bei **indirekten HAST** hingegen ist ein (oder auch mehrere) Wärmetauscher vorhanden, der den Fernwärmekreis vom Verbraucherkreis hydraulisch trennt. Diese Stationen bieten oft eine verbesserte Kontrolle über den Wärmeaustausch und ermöglichen eine bessere Anpassung an die spezifischen Bedürfnisse des Gebäudes. Des Weiteren können etwaige Verunreinigungen im Fernwärmenetz nicht ins Gebäude und umgekehrt gelangen. Dampfnetze erfordern immer eine hydraulische Trennung.

Die Betriebsverantwortung und Eigentumsrechte an der Hausanschlussstation liegen nicht zwangsläufig beim Netzbetreiber – die technischen Anschlussbedingungen (TAB) der FVU schaffen hier Klarheit, ob die neu zu errichtende HAST zum Netzbetreiber bzw. FVU oder zum Gebäude gehört. Dennoch ist ein Mischbestand aus HAST-Eigentumsrechten im Fernwärmenetz nicht unüblich, da entsprechende Vorgaben vom FVU bzw. Netzbetreiber gegebenenfalls erst später eingeführt wurden.



Mess-, Steuerungs- und Regelungseinheiten (MSR)-Techniken

Hausanschlussstationen erfordern MSR-Techniken, die es den HAST-Betreibern ermöglichen, die Temperaturen auf der Kundenseite bedarfsgerecht zu regeln. Je nach HAST-Typ und Hersteller werden unterschiedlich viele Regelorgane verwendet. In der Regel sind Absperr- und Regelungsarmaturen, Volumenstrombegrenzer, Differenzdruckregler, Druckmessgeräte, Rücklauftemperaturbegrenzer, Temperatursensoren (insbesondere die versorgerseitige Vor- und Rücklauftemperatur), Pumpen und der eigentliche Regler in einer Übergabestation enthalten. Manche Hersteller integrieren in die HAST ebenfalls Komponenten zur Regelung von Heizkreisen und Trinkwasserbereitungen, was zu einer starken Zunahme an Sensorik, Aktorik und der Regelungskomplexität führt. Des Weiteren ist ein geeichter Wärmemengenzähler (WMZ) zur Erfassung des Energieverbrauchs erforderlich, der unter anderem für Abrechnungszwecke verwendet wird.



Datenfernübertragung und Fernparametrierung

Im Zuge der Entwicklung hin zu Fernwärmenetzen der Generation 4.0 sollen Hausanschlussstationen zunehmend aus der Ferne gesteuert und überwacht werden. Dies ist Teil des Trends zur Digitalisierung und Automatisierung von Fernwärmenetzen, um die Effizienz zu steigern, den Energieverbrauch zu optimieren und den Betrieb zu vereinfachen. Durch die Integration von IoT-Technologien und intelligenten Steuerungssystemen können Betreiber Fernwärmenetze überwachen, Diagnosen durchführen, den Betrieb optimieren und bei Bedarf Einstellungen ändern, ohne physisch vor Ort sein zu müssen.

Diese Fernsteuerung und Fernüberwachung von Hausanschlussstationen ermöglicht es den Betreibern, den Betrieb des gesamten Fernwärmenetzes effizienter zu gestalten und auf Veränderungen in Echtzeit zu reagieren. Beispielsweise können sie die Temperatur in den Stationen anpassen, um die Energieabnahme zu optimieren oder auf Störungen frühzeitig zu reagieren, bevor sie zu größeren Problemen führen. Dies trägt zur Verbesserung der Zuverlässigkeit, Effizienz und Wirtschaftlichkeit des Fernwärmenetzes bei und bietet gleichzeitig eine bessere Kontrolle und Flexibilität für die Netzbetreiber, während für den Nutzenden Versorgungssicherheit und Komfort gesteigert werden.

Die Ablesung des Verbrauchszählers erfolgt entweder klassisch manuell oder über modernere (Funk-)Technologien wie LoRa (Long Range), NBloT (Narrow Band Internet of Things), SMGW (Smart Meter Gateway) etc. Um jedoch den Schritt zu Netzen der vierten Generation zu machen, ist neben dem Lesezugriff auch ein Schreibzugriff auf die Regelung der HAST erforderlich. Moderne HAST-Regelungssysteme verfügen zudem immer häufiger über Schnittstellen, welche die Einbindung in eine Plattform des Herstellers oder Dritter erlauben. Die genannten Technologien ermöglichen das Fernauslesen und -verstellen in größeren Maßstäben. Im Nachfolgenden wird eine vereinfachte Übersicht über Vor- und Nachteile der Kommunikationstechnologien gegeben. Die Bewertung erfolgt auf Basis eines Vergleichs der technischen Eckdaten sowie der Vor- und Nachteile des jeweiligen Verfahrens.

	Manuell	LoRa	NB IoT	SMWG
Kosten				
Komplexität				
Wechselintervall WMZ-Batterie				
Ausleseintervall (max.)				
Anzahl erhobener Datenpunkte				
Datenrate	-			
Reichweite	-			kabelgebunden
Durchdringung	-			-
Netzabdeckung	-	keine, Eigenbetrieb, ggf. Nutzung Netze Dritter	abhängig vom Standort	abhängig vom Standort
Lizensiertes Frequenzband	-			kabelgebunden



Tabelle 1: Vor- und Nachteile der Kommunikationstechnologien. Quelle: Eigene Darstellung in Anlehnung an Lora Alliance; Deutsche Telekom AG; Sagemcom Broadband SAS, 2024

Die Wahl der geeigneten Technologie hängt von verschiedenen Faktoren ab, einschließlich der Infrastruktur, der Budgetierung und der spezifischen Anforderung des Fernwärmenetzes. Mit Hilfe der Kommunikationstechnologie kann die HAST etwaige Parameteränderungen durch eine zentrale Stelle (ggf. durch die Leitwarte) entgegennehmen und umsetzen.



Leitwarte

Die Leitwarte ist das Kontrollzentrum des Fernwärmenetzes, in dem die Überwachung und Steuerung aller relevanten Prozesse erfolgt. Von hier aus werden die Wärmeerzeugungsanlagen und die Wärmeverteilung bis zu den HAST überwacht und gesteuert, um eine zuverlässige und effiziente Versorgung sicherzustellen. Die Leitwarte ist mit einem umfangreichen Netzwerk von Sensoren und Automatisierungssystemen verbunden, die kontinuierlich Daten über den Zustand des Netzes und der Wärmeerzeugungsanlagen liefern. Zu den auflaufenden Daten

zählen beispielsweise Wärmeerzeugerleistung, Netzvor- und Rücklauftemperaturen, Netzdifferenzdruck, Primärenergieeinsatz, Stör- sowie Statusmeldungen und viele mehr. Auf Basis dieser Daten können die Betreiber des Fernwärmenetzes Entscheidungen treffen und bei Bedarf eingreifen, um in der Wärmeerzeugung und -verteilung den Betrieb zu optimieren und Störungen zu beheben. Leitwarten von Fernwärmenetzen der Generation 4.0 umfassen zudem eine zielgerichtete Fernparametrierung von HAST, um den Netzlastgang zu beeinflussen. Die Leitwarte spielt somit eine entscheidende Rolle bei der Gewährleistung der Betriebssicherheit sowie Betriebsführung, der Energieeffizienz und der Kundenzufriedenheit im Fernwärmenetz. Aus diesem Grund zählt die Leitwarte eines Fernwärmenetzes zur kritischen Infrastruktur und bedarf besonders hoher IT-Sicherheitsmaßnahmen, welche unter anderem beim Wandel zur Generation 4.0 berücksichtigt werden müssen.



1.4. Künstliche Intelligenz

1.4.1. Einführung in die Künstliche Intelligenz

Die Welt der Künstlichen Intelligenz öffnet ein Universum an Möglichkeiten, das die Art und Weise, wie wir leben, arbeiten und interagieren, grundlegend verändert. Diese Technologie, die einst als Science-Fiction galt, ist heute eine treibende Kraft hinter vielen fortschrittlichen Anwendungen, von autonomen Fahrzeugen bis hin zu personalisierten Medizinlösungen. Die Geschichte der KI reicht von den ersten Träumen kognitiver Maschinen bis zu den modernen Errungenschaften des Deep Learnings und der neuronalen Netzwerke.

Aufgrund der Fülle an Informationen und der Komplexität der Thematik können in diesem Leitfaden nicht alle Aspekte der Künstlichen Intelligenz detailliert behandelt werden. Einige Inhalte mussten daher vereinfacht dargestellt werden, um einen Überblick zu ermöglichen. Dieser Leitfaden wurde speziell mit dem Fokus auf Betreiber von Fernwärmenetzen konzipiert, um ein grundlegendes Verständnis der KI und ihrer Anwendungsmöglichkeiten zu schaffen. Im weiteren Verlauf werden spezifische Anwendungsbeispiele und deren Implikationen für Fernwärmenetze diskutiert, um praktische Einblicke in die Nutzung von KI-Technologien in diesem Bereich zu bieten.

Es ist unser Ziel, ein fundiertes Basiswissen zu vermitteln, das als Grundlage für das Verständnis weiterführender Anwendungen dient. Für Leserinnen und Leser, die an einer tieferen Auseinandersetzung mit dem Thema interessiert sind, empfehlen wir ergänzende Literatur wie „Künstliche Intelligenz. Ein moderner Ansatz“ von Stuart Russell und Peter Norvig in der 4., aktualisierten Auflage 2023. Dieses Buch gilt als Standardwerk in der KI-Forschung und bietet einen umfassenden Überblick über die theoretischen und praktischen Aspekte der Künstlichen Intelligenz. Durch die Kombination aus diesem Leitfaden und weiterführenden Ressourcen können Betreiber von Fernwärmenetzen die Potenziale der KI voll ausschöpfen und innovative Lösungen für die Herausforderungen in ihrem Sektor entwickeln.

1.4.2. Definition und Abgrenzung: Was KI ist und wie sie sich von menschlicher Intelligenz unterscheidet

Die Definition und das Verständnis von KI sind komplex und vielschichtig, was nicht zuletzt an der Herausforderung liegt, menschliche Intelligenz selbst zu definieren. In der wissenschaftlichen Literatur existiert keine einheitliche Definition von menschlicher Intelligenz, was die Aufgabe, KI präzise zu definieren, zusätzlich erschwert. Die Autoren dieses Leitfadens betrachten Künstliche Intelligenz als ein Teilgebiet der Mathematik und Informatik, das sich mit der Erforschung und Entwicklung von adaptiven und autonomen Technologien zur Problemlösung beschäftigt. Anders als im allgemeinen Sprachgebrauch wäre nicht von „einer KI“ zu sprechen, sondern präziser von Methoden aus dem Bereich der Künstlichen Intelligenz.

Ein spezieller Bereich innerhalb der KI ist das maschinelle Lernen, das nach Arthur Samuel (1959) als ein Forschungsgebiet beschrieben wird, das Computer befähigt zu lernen, ohne explizit dafür programmiert zu sein. Einen allgemeinen Überblick der verschiedenen Teilbereiche der Künstlichen Intelligenz folgt im nächsten Kapitel anhand des „Circle of AI“.

Ein weiteres wichtiges Unterscheidungsmerkmal in der KI ist das zwischen schwacher und starker KI. Schwache KI ist auf spezifische Aufgaben beschränkt, während starke KI als noch weitgehend theoretisches Konzept das Potenzial besitzt, Bewusstsein oder Selbstbewusstsein zu entwickeln und jegliche kognitive Aufgabe auszuführen.

1.4.3. Von den Anfängen bis zu den aktuellen Durchbrüchen

Die Geschichte der Künstlichen Intelligenz ist facettenreich, beginnend mit den visionären Ideen des 20. Jahrhunderts bis hin zu den bahnbrechenden Entwicklungen der Gegenwart. Ein Schlüsselmoment in der Frühphase der KI war die Dartmouth-Konferenz im Sommer 1956, die oft als die Geburtsstunde der Künstlichen Intelligenz betrachtet wird. Dort kamen führende Wissenschaftler zusammen, um die Möglichkeiten der Maschinenintelligenz zu erforschen, was zu einem beispiellosen Forschungsschub in den darauffolgenden Jahrzehnten führte.

Ein wichtiger Meilenstein in der Entwicklung der KI war der Turing-Test, benannt nach dem britischen Mathematiker und Computerwissenschaftler Alan Turing. Im Jahr 1950 vorgeschlagen, dient dieser Test als experimentelles Kriterium zur Beurteilung der Fähigkeit einer Maschine, menschenähnliche Intelligenz zu demonstrieren. Turing stellte die Frage: „Können Maschinen denken?“ und schlug vor, die Leistung einer Maschine daran zu messen, ob sie in der Lage ist, in einem Gespräch mit einem Menschen nicht als Maschine erkannt zu werden (Russel, 2023).

Die Entwicklung der KI erlebte sowohl Höhenflüge als auch Rückschläge. Während des sogenannten „KI-Winters“ in den frühen 1970er Jahren wurden die Grenzen früher KI-Modelle deutlich, was zu einer zeitweiligen Reduktion in der Finanzierung und dem Interesse an der KI-Forschung führte. Jedoch führten Fortschritte in der Computerhardware, die Verfügbarkeit großer Datenmengen und die Entwicklung leistungsfähigerer Algorithmen zu einem erneuten Aufschwung in der KI-Forschung (Russel, 2023).


Ein eindrucksvolles Beispiel für die Fortschritte in der KI ist IBMs Schachcomputer Deep Blue, der 1997 als erster Computer den amtierenden Weltmeister Garri Kasparow in einem Schachmatch besiegte. Dieser Sieg demonstrierte die gewachsenen Fähigkeiten Künstlicher Intelligenz und machte einem breiten Publikum deutlich, dass KI-Systeme in der Lage sind, auch in komplexen strategischen Spielen menschliche Expertinnen und Experten zu übertreffen. Neben Deep Blue können weitere bedeutende Meilensteine erwähnt werden, wie die Entwicklung von AlphaGo, das den Weltmeister im Brettspiel Go besiegte, oder die Fortschritte in der automatischen Spracherkennung und -verarbeitung, die virtuelle Assistenten wie Siri und Alexa ermöglicht haben.

Fortschritte wie diese haben nicht nur die technologischen Grenzen erweitert, sondern auch die Diskussion über ethische Fragen und gesellschaftliche Auswirkungen angestoßen.

Die Popkultur hat maßgeblich dazu beigetragen, die öffentliche Wahrnehmung und die Erwartungen an KI zu formen. Von dystopischen Visionen bis hin zu utopischen Zukunftsbildern reicht das Spektrum, wie KI in Filmen und Literatur dargestellt

wird. Diese Darstellungen beeinflussen nicht nur, wie wir über KI denken, sondern auch, wie Wissenschaftler und Entwickler ihre Forschung und Entwicklung gestalten.

Die ethischen Überlegungen rund um KI sind vielfältig und komplex. Sie reichen von Datenschutzbedenken und der Automatisierung und damit Vernichtung von menschlichen Arbeitsplätzen bis hin zur Verantwortlichkeit für Entscheidungen, die von KI-Systemen getroffen werden. Gleichzeitig bietet KI das Potenzial, die Lebensqualität durch personalisierte Medizin, Bildung und nachhaltige Lösungen für globale Herausforderungen zu verbessern.



1.4.4. Teilbereiche der Künstlichen Intelligenz (Circle of AI)

Künstliche Intelligenz ist ein breites Feld mit zahlreichen Spezialisierungen, die jeweils einzigartige Herausforderungen und Lösungen bieten. Von der natürlichen Sprachverarbeitung, die es Computern ermöglicht, Text und Sprache wie ein Mensch zu verstehen, bis hin zur Robotik, die Maschinen befähigt, eigenständig durch die physische Welt zu navigieren, deckt KI ein breites Spektrum an Technologien ab. Andere Bereiche wie maschinelles Sehen und affektive Informatik eröffnen neue Möglichkeiten, indem sie Maschinen beibringen, visuelle Inhalte zu interpretieren und emotionale Reaktionen zu verstehen.

In Abbildung 1 werden verschiedene Teilbereiche der Künstlichen Intelligenz dargestellt. Natural Language Processing (NLP), Computer Vision (VS), Time Series Processing und Knowledge-Based Systems (KBS) werden als Anwendungsgebiete der Künstlichen Intelligenz (KI) bezeichnet. Diese Bereiche nutzen verschiedene Techniken, um spezifische Probleme zu lösen. Deep Learning und Reinforcement Learning sind zwei Unterkategorien des Machine Learning.

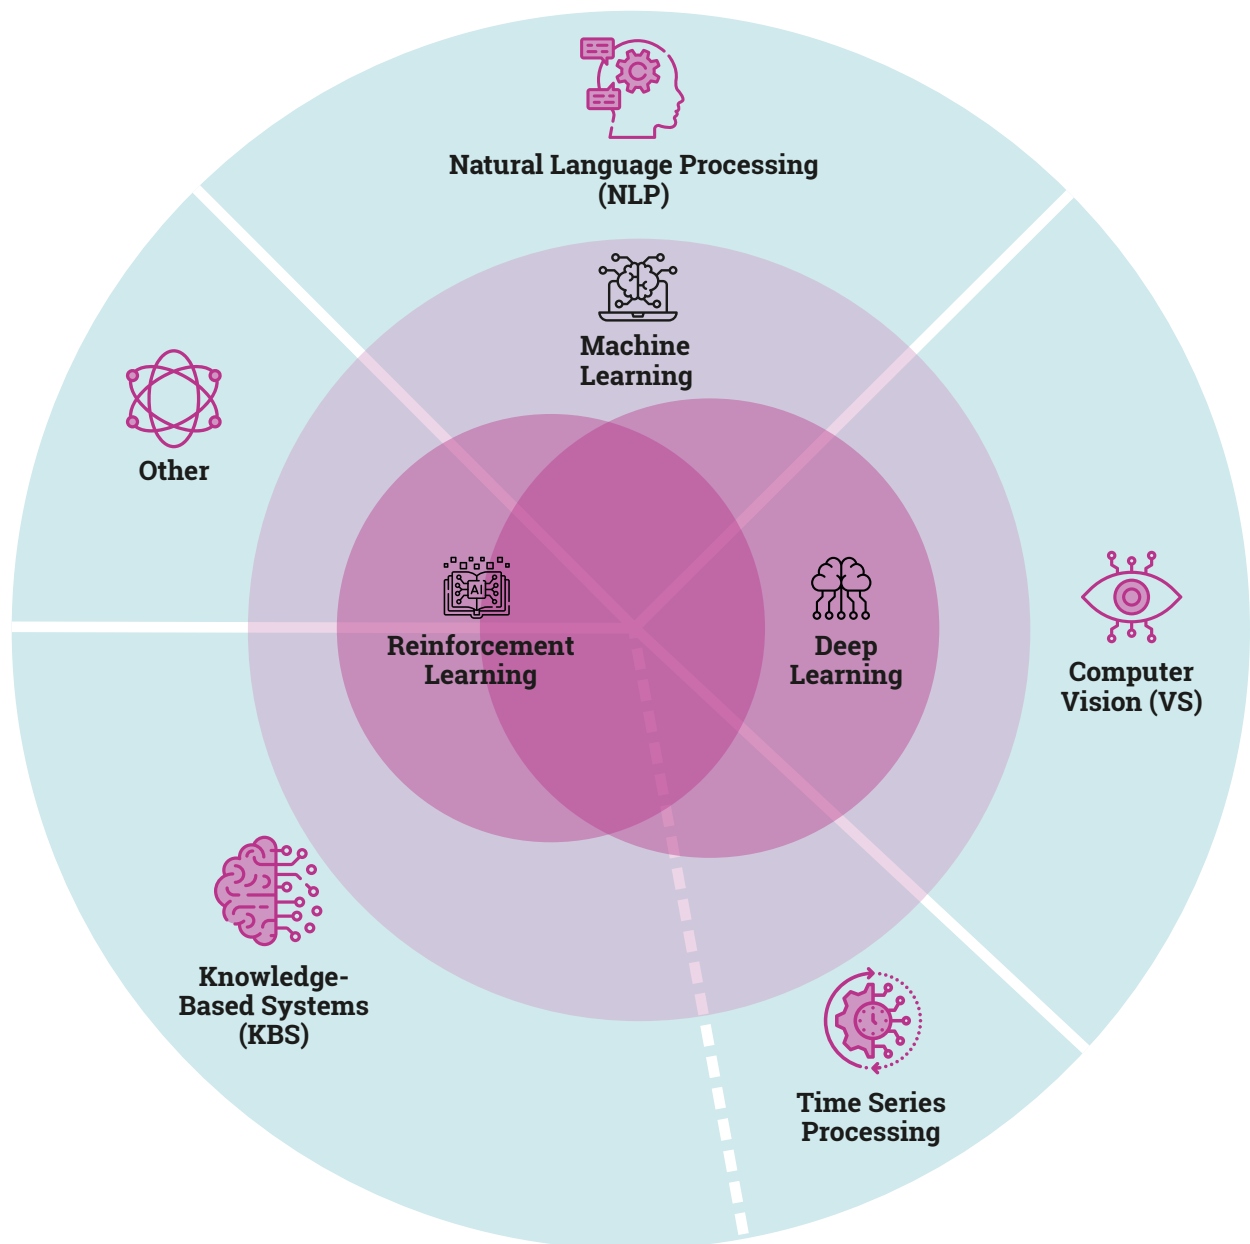


Abbildung 1: Circle of AI. Quelle: Eigene Darstellung in Anlehnung an RAUSCH Technology, 2024



Natürliche Sprachverarbeitung (NLP): Verarbeitung menschlicher Sprache durch Maschinen

Natürliche Sprachverarbeitung ist ein Bereich der Künstlichen Intelligenz, der sich mit der Verarbeitung und dem Verständnis menschlicher Sprache durch Maschinen beschäftigt. Im Kern ermöglicht NLP Computern, Text und gesprochene Worte zu analysieren, zu verstehen und zu generieren. Ein zentraler Aspekt von NLP ist die Spracherkennung und -generierung, welche die Umwandlung von gesprochener Sprache in Text und umgekehrt umfasst. Diese Technologien finden Anwendung in der Entwicklung von Sprachassistenten und automatisierten Kundenservice-Systemen.

NLP trägt auch maßgeblich zur Informationsverarbeitung und -suche bei, indem es Suchmaschinen befähigt, Nutzeranfragen präziser zu interpretieren und relevantere Ergebnisse zu liefern. Ein weiterer wichtiger Bereich ist die Sprachsynthese, die die Erzeugung von gesprochener Sprache aus Textdaten ermöglicht. Diese wird in Systemen wie digitalen Assistenten und bei der Sprachübersetzung eingesetzt. Durch die Fortschritte in der NLP-Technologie wird die Interaktion zwischen Menschen und Computern zunehmend effizienter und natürlicher.

Insbesondere der Generative Pre-trained Transformer (GPT) ist eine fortschrittliche Technologie, die innerhalb des Feldes der natürlichen Sprachverarbeitung entwickelt wurde. Als ein Beispiel für State-of-the-Art-Modelle im Bereich des maschinellen Lernens und speziell der Sprachmodelle repräsentiert GPT einen signifikanten Fortschritt in der Fähigkeit von Computern, menschliche Sprache zu verstehen und zu generieren. GPT basiert auf dem Transformer-Architekturprinzip, das es ermöglicht, große Mengen von Textdaten zu verarbeiten und daraus zu lernen, wodurch das Modell in der Lage ist, zusammenhängende und kohärente Texte zu generieren, Fragen zu beantworten, Texte zu übersetzen und viele weitere sprachbasierte Aufgaben zu erfüllen. In diesem Sinne kann GPT als ein spezifischer Ansatz oder Werkzeug innerhalb des breiteren Feldes der NLP betrachtet werden, der die Grenzen dessen erweitert, wie Maschinen menschliche Sprache verarbeiten und darauf reagieren.



Maschinelles Sehen: Interpretation von visuellen Informationen durch Computer

Maschinelles Sehen, auch bekannt als Computer Vision (CV), befasst sich mit der Fähigkeit von Computern, visuelle Informationen aus der Umwelt zu interpretieren und darauf zu reagieren. Diese Technologie ermöglicht es Maschinen, Bilder und Videos zu analysieren, zu verstehen und sogar eigene visuelle Inhalte zu generieren. Die Anwendungsgebiete reichen von der automatischen Bilderkennung und -klassifizierung bis hin zur Generierung von neuen Bildern und Videos.

Historische Ansätze des maschinellen Sehens basierten oft nicht auf neuronalen Netzen und nutzten stattdessen Techniken wie Mustererkennung und Bildverarbeitungsalgorithmen. Diese Methoden waren zwar grundlegend für die Entwicklung des Feldes, stießen jedoch schnell an ihre Grenzen, insbesondere bei der Verarbeitung komplexer oder variabler visueller Daten.

Der Durchbruch kam mit der Einführung und Weiterentwicklung von Deep-Learning-Technologien, insbesondere Künstlichen Neuronalen Netzen (KNN), die signifikant zum Erfolg des maschinellen Sehens in den letzten Jahren beigetragen haben. KNN sind besonders effektiv in der Erkennung von Mustern und Strukturen in visuellen Daten, was sie ideal für Aufgaben wie Gesichtserkennung, Objekterkennung und sogar die Generierung von Bildinhalten macht.

In jüngerer Zeit haben Technologien wie Midjourney und Dall-E die Möglichkeiten des maschinellen Sehens erweitert, indem sie komplexe Algorithmen nutzen, um aus Textbeschreibungen hochqualitative Bilder und Kunstwerke zu generieren. Diese Entwicklungen unterstreichen nicht nur die Fortschritte in der Technologie des maschinellen Lernens, sondern eröffnen auch neue Perspektiven für Kreativität und Design, indem sie es ermöglichen, visionäre Konzepte in visuelle Realitäten umzusetzen.

Maschinelles Sehen steht somit an der Schnittstelle von Technologie, Kunst und Wissenschaft und eröffnet durch die Integration von Deep-Learning-Methoden neue Horizonte für die Interaktion von Computern mit ihrer visuellen Umgebung. Die kontinuierliche Entwicklung in diesem Bereich verspricht spannende Fortschritte und Anwendungen, die weit über das bisher Mögliche hinausgehen.



Wissensbasierte Systeme: Speicherung und Verarbeitung von Wissen durch Computer

Wissensbasierte Systeme sind ein zentraler Bestandteil der Künstlichen Intelligenz und beschäftigen sich mit der Speicherung, Verarbeitung und Anwendung von Wissen. Diese Systeme sind darauf ausgerichtet, menschliches Fachwissen und Entscheidungsprozesse in einer Weise zu reproduzieren, die es Computern ermöglicht, komplexe Probleme zu lösen oder Entscheidungen zu treffen. Durch die Kombination aus gespeichertem Wissen und logischen Regeln können wissensbasierte Systeme auf eine Vielfalt von Fragestellungen reagieren und dabei die Logik von Expertinnen und Experten nachahmen.

Expertensysteme sind eine spezielle Form wissensbasierter Systeme, die das Wissen und die Erfahrung von Fachleuten in einem bestimmten Bereich nutzen, um Entscheidungen zu unterstützen. Diese Systeme werden oft in komplexen Umgebungen eingesetzt, in denen menschliche Expertinnen und Experten schwierige Entscheidungen treffen müssen, wie zum Beispiel in der Medizin, im Finanzwesen oder in den Ingenieurwissenschaften. Durch die Analyse der gespeicherten Daten und die Anwendung spezifischer Regelwerke können Expertensysteme Empfehlungen aussprechen oder Entscheidungen treffen, die denen menschlicher Expertinnen und Experten ähneln.

Entscheidungsmanagement ist ein weiterer wichtiger Aspekt wissensbasierter Systeme, der sich auf die automatisierte Entscheidungsfindung basierend auf Daten und Algorithmen konzentriert. Diese Systeme sind in der Lage, große Mengen an Daten zu analysieren, Muster zu erkennen und auf dieser Basis Entscheidungen zu treffen. Sie finden Anwendung in Bereichen wie Kundenmanagement, Betrugserkennung und Ressourcenplanung, wo schnelle und präzise Entscheidungen erforderlich sind.

i

Zeitreihen:

Zeitreihen sind Daten, die in einer zeitlichen Abfolge erfasst werden, wie Börsenkurse, Wetterdaten oder Sensordaten. Diese Daten sind sequentiell und ihre zeitliche Reihenfolge ist entscheidend für die Analyse. Ein Beispiel ist die Überwachung einer Heizungsanlage, bei der Sensordaten zu Temperatur und Energieverbrauch über die Zeit gesammelt werden. In der Zeitreihenanalyse werden Muster in den Daten erkannt, um zukünftige Ereignisse vorherzusagen. Univariate Zeitreihen enthalten eine Beobachtung pro Zeitschritt, während multivariate Zeitreihen mehrere Beobachtungen gleichzeitig erfassen. (Rausch, 2020)

Die Autoren dieses Leitfadens betrachten die Zeitreihenverarbeitung als integralen Bestandteil der wissensbasierten Systeme. Im spezifischen Anwendungsfall, der im weiteren Verlauf des Leitfadens vorgestellt wird, wird diese Technologie eingesetzt, um zu demonstrieren, wie wissensbasierte Systeme zur Lösung realer Probleme beitragen können.

Ein besonders wichtiges Anwendungsfeld der Zeitreihenverarbeitung ist die Vorhersage (Forecasting). Hierbei geht es darum, zukünftige Werte einer Zeitreihe basierend auf historischen Daten vorherzusagen. Diese Vorhersagen sind in zahlreichen Bereichen von entscheidender Bedeutung. In der Energiewirtschaft können beispielsweise zukünftige Verbrauchsmuster prognostiziert werden, um die Netzstabilität zu gewährleisten und die Effizienz der Energieverteilung zu optimieren. Im Finanzsektor hilft die Vorhersage von Aktienkursen oder wirtschaftlichen Indikatoren bei der Entscheidungsfindung und beim Risikomanagement.

Ein weiteres bedeutendes Anwendungsfeld ist die Anomalieerkennung (Anomaly Detection) in Zeitreihen. Dabei werden ungewöhnliche Muster oder Abweichungen von der Norm identifiziert, die auf Fehler, Betrug oder andere interessante Ereignisse hinweisen können. In der industriellen Produktion kann die Anomalieerkennung genutzt werden, um Maschinenausfälle oder Qualitätsprobleme frühzeitig zu erkennen und vorbeugende Maßnahmen zu ergreifen. Im Bereich der Netzwerksicherheit ermöglicht sie die Erkennung ungewöhnlicher Aktivitäten, die auf Sicherheitsverletzungen oder Cyberangriffe hindeuten könnten. Durch die Kombination von Zeitreihenverarbeitung und wissensbasierten Systemen können komplexe, zeitabhängige Probleme effizient gelöst werden.

Insgesamt bieten wissensbasierte Systeme, einschließlich Expertensystemen und Entscheidungsmanagement, einen Rahmen für die Speicherung, Analyse und Anwendung von Wissen in einer Weise, die die Entscheidungsfindung unterstützt und optimiert. Durch die Integration von Zeitreihenverarbeitung und Vorhersagetechniken erweitern sie die Fähigkeiten der Künstlichen Intelligenz und eröffnen neue Möglichkeiten für die Automatisierung und Verbesserung von Entscheidungsprozessen in verschiedenen Anwendungsbereichen.



Sonstige: Weitere Teilbereiche der Künstlichen Intelligenz


Neben den soeben vorgestellten Teilbereichen gibt es weitere, ebenso wichtige Bereiche der KI, die vielfältige Anwendungen finden. Dazu gehören beispielsweise Multiagentensysteme, verschiedene Aspekte der Robotik und die Affektive Informatik. Die Autoren dieses Leitfadens fassen diese Bereiche unter „Sonstige“ zusammen, was jedoch keineswegs ihre Bedeutung mindert. Im Gegenteil tragen diese Bereiche maßgeblich zur Weiterentwicklung und Anwendung von KI in verschiedensten Domänen bei.

Multiagentensysteme bestehen aus mehreren intelligenten Agenten, die miteinander interagieren und kooperieren, um komplexe Probleme zu lösen, die für einzelne Systeme unlösbar wären. Jeder Agent kann autonom handeln und verfügt über spezifische Fähigkeiten und Ziele. Die Zusammenarbeit dieser Agenten ermöglicht es, Aufgaben effizienter und robuster zu bewältigen. Multiagentensysteme finden Anwendung in der Logistik, wo sie beispielsweise die Koordination von Lieferketten optimieren. In der Verkehrssteuerung helfen sie, den Verkehrsfluss in Städten zu verbessern und Staus zu vermeiden. Verteilte Netzwerke wie Stromnetze oder Kommunikationssysteme profitieren ebenfalls von der Flexibilität und Skalierbarkeit von Multiagentensystemen.

In der Robotik gehen die Fähigkeiten der Maschinen weit über das maschinelle Sehen hinaus. Roboter sind in der Lage, autonome Entscheidungen zu treffen und komplexe Bewegungsabläufe zu planen. In der Industrie kommen sie beispielsweise bei der Montage, Inspektion und Wartung von Anlagen zum Einsatz. In der Gesundheitsversorgung unterstützen sie bei Operationen, der Rehabilitation und der Pflege von Patienten. Haushaltsroboter übernehmen Aufgaben wie Staubsaugen oder Rasenmähen. Diese Roboter nutzen fortgeschrittene Algorithmen und Sensortechnologien, um ihre Umgebung zu verstehen und darauf zu reagieren. Durch ihre Fähigkeit, in dynamischen und unstrukturierten Umgebungen zu arbeiten, eröffnen sie neue Möglichkeiten in zahlreichen Anwendungsfeldern.

Affektive Informatik befasst sich mit der Erkennung und Interpretation menschlicher Emotionen durch Maschinen. Diese Technologie ermöglicht es, die Interaktion zwischen Mensch und Maschine natürlicher und effektiver zu gestalten. Anwendungen finden sich in der Entwicklung von persönlichen Assistenten, die auf die Stimmung ihrer Nutzerinnen und Nutzer reagieren können, sowie in der Automobilindustrie, wo Fahrerassistenzsysteme den emotionalen Zustand der Fahrerinnen und Fahrer überwachen, um die Sicherheit zu erhöhen. Auch im Bildungsbereich kann Affektive Informatik eingesetzt werden, um das Lernen zu personalisieren und die Motivation der Schülerinnen und Schüler zu steigern.

Diese KI-Bereiche erweitern die Möglichkeiten der Technologie erheblich und bieten innovative Lösungen für Herausforderungen in verschiedenen Sektoren. Durch ihre adaptiven und autonomen Fähigkeiten tragen sie maßgeblich dazu bei, die Interaktion zwischen Mensch und Maschine zu verbessern und neue Anwendungsfelder zu erschließen.



1.4.5. Daten und Künstliche Intelligenz

Der Kern jeder Anwendung mit Methoden der Künstlichen Intelligenz setzt sich aus Daten, Algorithmen und Modellen zusammen, welche die Grundlage für maschinelles Lernen und intelligente Entscheidungsfindung bilden. Daten sind eine elementare Voraussetzung für den Bereich der Künstlichen Intelligenz, und ihre Qualität, Vielfalt und Verarbeitung bestimmen den Erfolg von KI-Systemen. Algorithmen sind die Mechanismen, durch die Maschinen aus Daten lernen, während Modelle das Endprodukt dieser Lernprozesse darstellen, angewandt auf spezifische Probleme.

Datenmanagement und -aufbereitung: Wichtigkeit von Datenqualität, -bereinigung und -vorverarbeitung

Die sorgfältige Vorverarbeitung von Daten spielt eine entscheidende Rolle in der Entwicklung effektiver KI-Systeme. Ein Großteil des Erfolgs von KI-Projekten hängt von der Qualität und der Repräsentativität der verwendeten Daten ab. Der Grundsatz „Garbage in, garbage out“ verdeutlicht, dass die Qualität der Eingabedaten direkt die Güte der Modellergebnisse beeinflusst. Ungenügende oder verzerrte Datensätze können um Modell-Bias führen, was die Fairness und Genauigkeit der KI-Anwendungen erheblich beeinträchtigt. Daher ist es von größter Wichtigkeit, dass die Daten das zu lösende Problem adäquat widerspiegeln. So kann ein nicht für das Problem repräsentativer Datensatz bei einer Klassifikation dazu führen, dass einzelne Klassen unverhältnismäßig oft angewendet werden, obwohl diese in Wirklichkeit nur sehr viel seltener vorkommen.

Die Annotation oder das Labeling von Daten ist ein zentraler Schritt in der Datenvorverarbeitung, der oft Expertenwissen aus der jeweiligen Domäne erfordert. Dieser Prozess kann sehr aufwändig sein, da er eine genaue Überprüfung und Kategorisierung der Daten beinhaltet, um sie für das Training von KI-Modellen nutzbar zu machen. Die Erstellung einer qualitativ hochwertigen Datenbasis ist somit ein zeit- und ressourcenintensiver Prozess, der jedoch für den Erfolg von KI-Anwendungen unerlässlich ist. Solch eine Datenbasis stellt ein wertvolles Asset dar, da sie die Grundlage für trainierte Modelle bildet, die zuverlässige und faire Ergebnisse liefern sollen.

Datenwissenschaftler (Data Scientists) spielen eine wichtige Rolle in der Phase der explorativen Datenanalyse, indem sie die Daten untersuchen, um Muster, Trends und mögliche Korrelationen zwischen verschiedenen Merkmalen zu identifizieren. Diese Phase ist entscheidend, um ein tiefes Verständnis der Daten zu erlangen und um wichtige Einsichten zu gewinnen, die die Modellentwicklung und -auswahl informieren können. Beispielsweise kann die Entdeckung einer starken Korrelation zwischen zwei Variablen darauf hinweisen, dass eine von ihnen als prädiktives Merkmal in einem Modell verwendet werden kann.

Die Automatisierung der Datenvorverarbeitung ist ein weiterer wichtiger Aspekt, der oft durch ETL-Pipelines (Extract, Transform, Load) realisiert wird. Diese Pipelines ermöglichen es, Daten automatisiert aus einer Vielzahl von Quellen zu extrahieren, sie zu transformieren – indem sie gereinigt, angereichert und in ein einheitliches Format gebracht werden – und schließlich in einem Ziel-System zu speichern, wo sie für das Training und die Anwendung von KI-Modellen verfügbar sind. ETL-Pipelines sind entscheidend für die Effizienz und Skalierbarkeit von KI-Projekten, da sie die wiederholte manuelle Bearbeitung von Daten minimieren und einen konsistenten, automatisierten Prozess für die Datenvorverarbeitung bieten.

Insgesamt sind die sorgfältige Auswahl, Vorverarbeitung und Analyse von Daten von unschätzbarem Wert für die Entwicklung effektiver KI-Systeme. Eine qualitativ hochwertige Datenbasis ist das Rückgrat jeder KI-Anwendung, das nicht nur die Genauigkeit und Fairness der Ergebnisse sichert, sondern auch die Grundlage für weiterführende Innovationen im Bereich der Künstlichen Intelligenz bildet.

1.4.6. Algorithmen und Modellierungsansätze: Überblick über die wichtigsten KI-Algorithmen und ihre Anwendungen

Algorithmen und Modellierungsansätze bilden das Herzstück Künstlicher Intelligenz und treiben eine Vielzahl von Anwendungen voran. Grundlegend unterscheidet man zwischen zwei Hauptparadigmen des maschinellen Lernens: Supervised Learning (überwachtes Lernen) und Unsupervised Learning (unüberwachtes Lernen).

Beim Supervised Learning werden Modelle mit einem Datensatz trainiert, der sowohl Eingaben (Features) als auch die zugehörigen Ausgaben (Labels) enthält. Ziel ist es, aus diesen Beispielen zu lernen, um Vorhersagen für neue, unbekannte Daten treffen zu können. Die zwei primären Anwendungen in diesem Paradigma sind Klassifikation und Regression. Klassifikation wird verwendet, um Eingabedaten einer bestimmten Kategorie zuzuordnen, während Regression darauf abzielt, eine kontinuierliche Ausgabe vorherzusagen. Ein praktisches Beispiel für Supervised Learning ist ein Spam-Filter, der auf der Basis von gelabelten E-Mails (Spam oder kein Spam) trainiert wird. Anstatt starrer Regeln, die leicht von Spammern umgangen werden können, lernt das Modell, Merkmale von Spam-Mails eigenständig zu identifizieren und zu generalisieren, um auch neue, unbekannte Mails korrekt zu klassifizieren (Géron, 2023).

Unsupervised Learning hingegen arbeitet mit Datensätzen ohne vordefinierte Labels. Es zielt darauf ab, Strukturen oder Muster innerhalb der Daten eigenständig zu erkennen. Ein verbreiteter Anwendungsfall ist das Clustering, das ähnliche Datenpunkte in Gruppen zusammenfasst, sowie die Generierung von Assoziationsregeln, die Beziehungen zwischen Variablen

aufzeigen. Diese Techniken sind nützlich, um tiefergehende Einsichten in die Datenstruktur zu gewinnen oder um verborgene Muster ohne vorherige Kenntnis zu entdecken (Rausch, 2020). Beispiele hierfür sind im Kontext des Energiesektors Fehlerdiagnosen in Erzeugungsanlagen, Predictive Maintenance für Wartung und Instandhaltung oder auch Analyse und Überwachung von Netzen zur Erkennung von Anomalien (FFE, 2020).

Insgesamt bieten diese Algorithmen und Modellierungsansätze eine robuste Grundlage für die Entwicklung leistungsfähiger KI-Systeme, die eine breite Palette von realen Problemen adressieren und lösen können.

Es gibt eine Vielzahl von Algorithmen, die zur Lösung unterschiedlichster Probleme eingesetzt werden können. Diese reichen von einfachen linearen Regressionsmodellen bis hin zu komplexen neuronalen Netzwerken. Die Auswahl des passenden Algorithmus hängt stark von der Art des Problems, der Beschaffenheit der Daten und den spezifischen Anforderungen des Anwendungsfalls ab. Es gibt keinen universellen Algorithmus, der für alle Szenarien optimal ist. Daher ist es entscheidend, verschiedene Algorithmen zu testen und zu evaluieren, um herauszufinden, welcher die beste Leistung für eine spezifische Aufgabe bietet.

Der Prozess der Auswahl und Evaluierung von Algorithmen umfasst in der Regel das Experimentieren mit verschiedenen Modellarchitekturen, Hyperparameter-Tunings und Trainings-techniken. Es ist auch wichtig, die Modelle unter realen Bedingungen zu testen, um ihre Fähigkeit zur Generalisierung auf unbekannte Daten zu bewerten. Diese sorgfältige Evaluation hilft nicht nur dabei, das leistungsfähigste Modell zu identifizieren, sondern gibt auch Aufschluss über die Stärken und Schwächen verschiedener Ansätze in Bezug auf das betrachtete Problem.

In einigen Fällen kann es sinnvoll sein, mehrere Modelle zu kombinieren, um die Genauigkeit weiter zu verbessern. Techniken wie Ensemble-Learning, bei denen die Vorhersagen mehrerer Modelle zusammengeführt werden, können oft zu besseren Ergebnissen führen als die Verwendung eines einzelnen Modells.

Letztlich ist die erfolgreiche Anwendung von KI-Algorithmen eine iterative und explorative Aufgabe, die ein tiefes Verständnis sowohl der verfügbaren Technologien als auch des zu lösenden Problems erfordert. Durch kontinuierliches Testen, Lernen und Anpassen können Entwickler und Datenwissenschaftler effektive Lösungen konstruieren, die spezifische Herausforderungen adressieren und wertvolle Einblicke oder Automatisierungsmöglichkeiten bieten.

Spezialfall Deep-Learning

Deep Learning, eine Untergruppe des maschinellen Lernens, basiert auf künstlichen neuronalen Netzen mit vielen Schichten



Was sind Hyperparameter?

Hyperparameter sind Einstellungen, die die Struktur und das Verhalten eines KI-Modells vor dem Training festlegen. Im Gegensatz zu den Parametern eines Modells, die während des Trainings aus den Daten gelernt werden, müssen Hyperparameter manuell definiert werden. Beispiele für Hyperparameter sind die Lernrate, die Anzahl der Schichten in einem neuronalen Netzwerk oder die Tiefe in einem Entscheidungsbaum. Das Anpassen dieser Hyperparameter ist entscheidend, da sie einen erheblichen Einfluss auf die Modellleistung haben. Durch systematisches Hyperparameter-Tuning können optimale Einstellungen gefunden werden, die das Modell sowohl leistungsfähiger als auch robuster machen.

(den sogenannten „tiefen“ Netzen). Diese Technik ermöglicht es Computern, komplexe Muster und Zusammenhänge in großen Datenmengen zu erkennen, indem sie Strukturen in einer Weise lernen, die der menschlichen Informationsverarbeitung im Gehirn nachempfunden ist.

Das Funktionsprinzip von Deep Learning besteht darin, dass Eingabedaten (wie Bilder oder Texte) durch mehrere Schichten des neuronalen Netzes fließen. Jede Schicht extrahiert bestimmte Merkmale aus den Daten. Die ersten Schichten erkennen einfache Muster, während nachfolgende Schichten immer komplexere Merkmale identifizieren. Durch diesen schrittweisen Prozess kann das Netzwerk schließlich komplexe Zusammenhänge in den Daten erkennen und Aufgaben wie Bilderkennung, Sprachverarbeitung oder Vorhersagemodelle mit hoher Genauigkeit ausführen.

Der Erfolg von Deep Learning in den letzten Jahren lässt sich durch mehrere Faktoren erklären. Obwohl die theoretischen Grundlagen bereits in den 1940er Jahren gelegt wurden, fehlte es lange Zeit an ausreichender Rechenleistung und genügend großen Datenmengen, um diese Netze effektiv zu trainieren. Mit dem exponentiellen Wachstum der verfügbaren Daten und der dramatischen Steigerung der Rechenkapazität, vor allem durch die Entwicklung spezialisierter Hardware, hat Deep Learning einen Durchbruch erlebt.

Besonders Grafikkarten (GPU), die ursprünglich für die Anforderungen von Computerspielen und CAD-Anwendungen entworfen wurden, haben sich als besonders geeignet für die Parallelisierung der Berechnungen in neuronalen Netzen erwiesen. Ihre Fähigkeit, viele Operationen gleichzeitig auszuführen, beschleunigt das Training von tiefen neuronalen Netzen erheblich. Mittlerweile gibt es speziell für Deep Learning entwickelte Hardware, die noch effizientere und schnellere Berechnungen ermöglicht.

Diese Fortschritte in der Hardware-Technologie, gepaart mit der Verfügbarkeit großer Datenmengen, haben Deep Learning zu einer der treibenden Kräfte in der Entwicklung fortschrittlicher KI-Anwendungen gemacht.

Spezialfall Reinforcement Learning

Reinforcement Learning (bestärkendes Lernen) stellt ein weiteres wichtiges Paradigma im Bereich des maschinellen Lernens dar. Es unterscheidet sich von überwachten und unüberwachten Lernmethoden durch seine interaktive Natur. Im Reinforcement Learning agiert ein Agent in einer bestimmten Umgebung und lernt durch das Ausprobieren verschiedener Strategien, die optimale Handlungsweise zu ermitteln. Dabei erhält der Agent Feedback in Form von Belohnungen oder Strafen, was ihm hilft, seine Entscheidungen zu verbessern.

Ein zentrales Konzept im Reinforcement Learning ist die Belohnungsfunktion. Diese Funktion bewertet die Aktionen des Agenten und gibt an, wie gut oder schlecht eine bestimmte Aktion in einem bestimmten Zustand ist. Ziel des Agenten ist es, die kumulative Belohnung über die Zeit zu maximieren. Dazu nutzt der Agent eine Strategie (Policy), die bestimmt, welche Aktion in welchem Zustand ausgeführt wird.

Ein weiteres wichtiges Element ist die Wertfunktion, die den erwarteten Nutzen (Belohnung) eines Zustands oder einer Aktion angibt. Eine spezifische Methode zur Schätzung dieser Wertfunktionen ist Q-Learning. Hierbei spielt der Begriff Q-Werte eine zentrale Rolle. Q-Werte repräsentieren die Qualität einer bestimmten Aktion in einem bestimmten Zustand. Sie geben dem Agenten einen Hinweis darauf, wie vorteilhaft es ist, eine bestimmte Aktion in einem bestimmten Zustand auszuführen, um langfristig die maximale Belohnung zu erhalten. Der Agent aktualisiert die Q-Werte durch wiederholte Interaktionen mit der Umgebung, indem er die folgenden Schritte durchführt:

- i. Der Agent führt eine Aktion in einem bestimmten Zustand aus.
- ii. Er erhält eine sofortige Belohnung und wechselt in einen neuen Zustand.
- iii. Der Agent aktualisiert den Q-Wert für die Aktion im ursprünglichen Zustand, basierend auf der erhaltenen Belohnung und den zukünftigen Q-Werten im neuen Zustand.

Reinforcement Learning eignet sich besonders für Probleme, bei denen eine direkte Zuordnung von Eingaben zu Ausgaben schwierig ist. Ein prominentes Beispiel ist die Entwicklung von selbstlernenden Spielsystemen. Hier kann der Agent durch wiederholtes Spielen und Experimentieren lernen, wie er gewinnen kann. Ein bekanntes Beispiel ist AlphaGo von DeepMind, das durch Reinforcement Learning den Weltmeister im Go besiegte.

Ein weiteres Anwendungsgebiet ist die autonome Navigation. Selbstfahrende Fahrzeuge nutzen Reinforcement Learning, um

sicher und effizient durch komplexe Umgebungen zu navigieren. Der Agent lernt durch Simulation und reale Fahrten, wie er auf verschiedene Verkehrsbedingungen reagieren soll, um Unfälle zu vermeiden und Ziele effizient zu erreichen.

Auch in der Robotik findet Reinforcement Learning Anwendung, um Roboter zu befähigen, komplexe Aufgaben zu erlernen, wie das Greifen und Manipulieren von Objekten. Hierbei lernt der Roboter durch Versuch und Irrtum die besten Strategien, um mit seiner Umgebung zu interagieren.

1.4.7. Training und Validierung

Ergänzend zu den grundlegenden Algorithmen und Modellierungsansätzen ist der Trainingsprozess von Modellen ein weiterer entscheidender Aspekt, der maßgeblich die Leistungsfähigkeit und Anwendbarkeit Künstlicher Intelligenz bestimmt. Dabei kommen verschiedene Trainingsmethoden zum Einsatz, von denen Batch-, Online- und Transferlernen die bekanntesten sind. Während das Batch-Lernen große Datenmengen in kompletten Durchläufen verarbeitet, erlaubt das Online-Lernen eine kontinuierliche Anpassung des Modells anhand neu eintreffender Daten. Transferlernen wiederum beschleunigt den Lernprozess, indem bereits erworbenes Wissen auf neue, ähnliche Aufgaben übertragen wird.

Für die Überprüfung der Modellgenauigkeit und zur Vermeidung von Overfitting – der Überanpassung an die Trainingsdaten, welche die Vorhersagegenauigkeit mit neuen Daten verringert – sind Validierungsstrategien unerlässlich. Eine weit verbreitete Technik ist die Cross-Validation, bei der der Datensatz in mehrere Segmente unterteilt wird, um das Modell mehrfach zu trainieren und zu testen. Dies verbessert die Zuverlässigkeit der Leistungsbewertung des Modells.

Ein entscheidender Schritt im Trainingsprozess ist die Aufteilung der verfügbaren Daten in Trainings- und Validierungsdaten. Typischerweise wird der Datensatz im Verhältnis 80/20 aufgeteilt, wobei 80 Prozent der Daten zum Training des Modells verwendet werden und 20 Prozent als Validierungsdaten zurückgehalten werden. Diese Validierungsdaten dürfen während des Trainingsprozesses nicht verwendet werden. Sie dienen ausschließlich dazu, die Leistung des Modells nach Abschluss des Trainings zu bewerten. Dies stellt sicher, dass das Modell nicht nur auf den Trainingsdaten gut performt, sondern auch auf neuen, bisher unbekanntenen Daten effektiv funktioniert.

Die Anwendung dieser Trainings- und Validierungsstrategien trägt entscheidend dazu bei, die Generalisierungsfähigkeit der Modelle zu erhöhen. Sie ermöglichen es, dass KI-Systeme nicht nur auf den ihnen bekannten Daten gute Ergebnisse liefern, sondern auch unbekannte, neue Daten effektiv verarbeiten und interpretieren können. Durch diese sorgfältige Vorbereitung und Prüfung wird sichergestellt, dass KI-Modelle robust, zuverlässig und für ein breites Anwendungsspektrum geeignet sind.

1.5. Ethik und Verantwortung

Beim Einsatz von KI in Unternehmen ist die Auseinandersetzung mit Ethik, Datenschutz und Datensicherheit für einen verantwortungsvollen Umgang essenziell. Verantwortungsvolle KI erfordert die Schaffung von Rahmenbedingungen für die Bewertung, den Einsatz und die Überwachung der Anwendungen. Der ethische Umgang mit neuen Technologien bedeutet, Lösungen zu entwerfen, die den Menschen in den Mittelpunkt stellen. Dieses Kapitel gibt einen knappen Überblick über die aktuelle Diskussion sowie zu relevanten Publikationen staatlicher sowie nichtstaatlicher Organisationen. Parallel zu der rasanten Entwicklung von KI sind gleichzeitig große Initiativen, politische Statements und Expertenkommissionen entstanden, die sich mit Ethikgrundsätzen sowie Werten und Reglementierungen beschäftigen. Die Mehrheit orientiert sich dabei an den politischen Strategien der EU und ihrer Mitgliedstaaten. Hinsichtlich des Energiebereichs ist vor allem der Umgang mit Daten, insbesondere Kundendaten, von Bedeutung. Die fortschreitende Digitalisierung der Netze erfordert einen gewissenhaften und sicheren Umgang bezüglich der Aufbewahrung und der Nutzung sowie die Einhaltung geltender Vorschriften.

Öffentliche Diskussionen über den Nutzen von KI sind nicht selten von Skepsis und Vorurteilen geprägt. Die Sicherstellung eines ethischen Umgangs mit derartigen Technologien ist daher eine zentrale Forderung an Unternehmen, die von Verbraucherinnen und Verbrauchern sowie staatlichen und nichtstaatlichen Organisationen gestellt wird. Die UNESCO hat im Jahr 2021 den ersten global verhandelten Völkerrechtstext zum Thema Ethik der Künstlichen Intelligenz veröffentlicht und darin Handlungsempfehlungen in elf Politikfeldern beschrieben. Darunter befindet sich beispielsweise auch der Bereich der Datenpolitik. Die Empfehlungen sollen als ethische Prinzipien dienen, an denen sich die UNESCO-Mitgliedstaaten bei der Entwicklung und Umsetzung von Gesetzen sowie Steuerungsinstrumenten orientieren können (UNESCO, 2022). Die deutsche UNESCO-Kommission folgte 2023 mit einer Veröffentlichung, die die weltweite Empfehlung als inhaltliches Fundament nutzt, um konkrete Handlungsempfehlungen sowie Vorschläge für die Implementierung in Deutschland zu formulieren (UNESCO, 2022).

Zentrale Schlagworte, die den Wertegehalt von ethischen KI-Anwendungen beschreiben, sind Transparenz und Erklärbarkeit, Beobachtbarkeit, Robustheit sowie Verantwortung und Haftung. Die Organisation für wirtschaftliche Zusammenarbeit und Entwicklung (OECD) erkannte 2019 die Notwendigkeit internationaler Richtlinien an und betonte, dass Akteure im Bereich der KI sich zu Transparenz und verantwortungsvoller Offenlegung in Bezug auf KI-Systeme verpflichten sollten. Ziel sollte es sein, ein allgemeines Verständnis für KI-Systeme, einschließlich ihrer Fähigkeiten und Grenzen, zu fördern sowie die Möglichkeit zur Nachvollziehbarkeit von Inhalten

und Entscheidungen zu gewährleisten (OECD, 2019). Ebenso betont der Deutsche Ethikrat 2023 in einer Stellungnahme die Relevanz von Transparenz, Nachvollziehbarkeit, Kontrolle und Verantwortung im Kontext von KI-Systemen. Laut dem Ethikrat müsse jegliche Intransparenz begründet werden. Es sei erforderlich, ausgewogene Standards zu entwickeln, die auf die jeweiligen Aufgaben, Zielgruppen und Kontexte zugeschnitten sind. Diese Standards sollten Transparenz, Erklärbarkeit und Nachvollziehbarkeit betonen, da sie für Kontrolle und Verantwortung wesentlich sind. Zudem müssen verbindliche technische und organisatorische Vorgaben zur Umsetzung dieser Standards erstellt werden (Deutscher Ethikrat, 2022).

Digitale Infrastrukturen, die möglicherweise auch über das Internet gesteuert werden, weisen ein erheblich höheres Risiko für Hackerangriffe, technische oder soziotechnische Systemversagen auf als separierte, geschlossene Infrastrukturen. Auch hier appelliert der Deutsche Ethikrat an ein ethisches Vorsorgedenken, um solche Gefahren frühzeitig zu minimieren. Es ist zu beobachten, dass das Risiko für Cyberangriffe steigt und somit auch die Notwendigkeit zur Auseinandersetzung mit Datensicherheit wichtiger wird. Eine Umfrage der Bitkom aus dem Jahr 2019 zeigt die wachsende Herausforderung durch Cyberattacken. Laut der Studie wurden etwa drei Viertel aller befragten Unternehmen Opfer von Cyberattacken und mussten mit teils erheblichen, kostenintensiven Schäden umgehen (bitkom, 2019). IT-Sicherheit bei KI-Systemen wird außerdem in der Veröffentlichung der Roadmap zu Normen und Standards der Künstlichen Intelligenz von dem Deutschen Institut für Normung (DIN), der Deutschen Kommission Elektrotechnik Elektronik Informationstechnik (DKE) und dem Bundesministerium für Wirtschaft und Klimaschutz (BMWK) als ein Schwerpunktthema behandelt. Sicherheit, insbesondere IT-Sicherheit, wird oft als hinderlich für Innovationen betrachtet und erhöht meist die Kosten und den Aufwand eines Unternehmens. Ohne sie sind die Risiken und Schäden jedoch erheblich höher. Die erforderliche Sicherheit hängt von einer Risikobewertung ab, die den Aufwand gegen den möglichen Schaden abwägt. Vertrauen, zum Beispiel durch den Nachweis von Datensicherheit, ist essenziell für die wirtschaftliche Nutzung solcher Anwendungen. In der Normungsroadmap wird außerdem die Forderung formuliert, dass etablierte Regulierungen für IT-Systeme auch für KI-Systeme greifen sollten, wie beispielsweise bezüglich der Sicherheit eines Systems, der Sicherheit der Daten sowie des Datenschutzes (DIN, 2022).

Als europäische Regulation für den verantwortungsvollen Einsatz von KI trat im März 2024 der Artificial Intelligence Act (AI-Act) in Kraft. Der AI-Act soll auf europäischer Ebene dazu beitragen, mehr Vertrauen zu schaffen und einen sicheren Umgang mit KI zu gewährleisten. Die Verordnung regelt, wofür und unter welchen Bedingungen KI eingesetzt werden darf.

Sie orientiert sich dabei an vier Risikostufen. Es gilt ein Verbot für Risikostufe 1 mit unannehmbaren Risiken, wie zum Beispiel soziale Bewertungssysteme, während bei Stufe 2 die meisten Verpflichtungen für Anwendungen mit hohem Risiko gelten. Anwendungen von Stufe 3 mit geringerem Risiko unterliegen nur wenigen Transparenzpflichten, und Stufe 4 mit geringstem Risiko ist weitestgehend unreguliert. Die Versorgung mit Energie, Wasser, Gas, Wärme oder Strom gehört als kritische Infrastruktur zur Stufe mit hohem Risiko (Stufe 2). Damit gehen höhere Anforderungen an den Einsatz von KI einher, wie etwa ein ganzheitliches Risikomanagement, ein bestimmtes Maß an Genauigkeit, Cybersicherheit und Robustheit sowie die Implementierung menschlicher Aufsicht (Das Europäische Parlament und der Rat der Europäischen Union, 2024).

Ein verantwortungsvoller Umgang mit KI-Systemen umfasst nicht nur den Schutz von Daten und die Gewährleistung der Datensicherheit, sondern auch die Berücksichtigung ökologischer und sozialer Risiken sowie die Förderung fairer Märkte. Demnach sollten beispielsweise ökologische Vorteile gegen den hohen Energie- und Ressourcenverbrauch von KI abgewogen sowie die Risiken und Folgen für Arbeitnehmerinnen und Arbeitnehmer durch den Einsatz von KI berücksichtigt werden (Zimmermann, 2019).

Trotz Regulierung ist es weiterhin von großer Bedeutung, auch proaktiv Maßnahmen zu ergreifen, um einen ethischen und verantwortungsvollen Umgang mit KI garantieren zu können. Viele Initiativen, Organisationen und Kommissionen formulieren daher parallel zu den rasanten technologischen Entwicklungen wichtige Empfehlungen an Unternehmen, um in Zukunft eine nachhaltige und vertrauensvolle Nutzung neuer Technologien zu gewährleisten.



2.

KI-Anwendungsfälle


Wo genau kann KI im Fernwärmenetz nun zum Einsatz kommen? Nicht jeder mögliche KI-Anwendungsfall ist auch ein guter KI-Anwendungsfall. Auch sind die für gut befundenen Anwendungsfälle des einen Unternehmens nicht gleich passende Anwendungsfälle für ein anderes Unternehmen. Bei der individuellen Kosten-Nutzen-Analyse gilt immer die Prämisse, zunächst die Effektivität der eigenen vorhandenen Prozesse zu evaluieren und ein mögliches Verbesserungspotenzial abzuschätzen. Bereits sehr gut optimierte Prozesse bieten gegebenenfalls nur noch wenig Spielraum zur Verbesserung.

Auch wenn diese Prozesse in ein „Spezialgebiet“ von KI-basierten Verfahren (wie beispielsweise Zeitreihenprognosen) fallen, kann der Aufwand zur Implementierung eines KI-basierten Verfahrens gegenüber dem Nutzen der Optimierung von letzten Prozentpunkten überwiegen. Es sollte zunächst geprüft werden, ob die Datengrundlage im eigenen Unternehmen ausreichend ist, um einen Prozess mit einem KI-basierten Verfahren zu unterstützen, zu ergänzen bzw. zu ersetzen, oder ob es sich lohnt, die generelle Datengrundlage zu verbessern.

2.1. Methodisches Framework

Um beantworten zu können, wo und wie KI in Fernwärmenetzen zum Einsatz kommen kann, wurden im Rahmen des Projekts in einer zweiteiligen Workshop-Reihe konkrete Anwendungsfälle erarbeitet. Die benötigte Expertise aus dem Wärmesektor lieferten dabei 34 Teilnehmende mit einem gleichmäßigen Verhältnis aus KI-Lösungsanbietern, FVU, Verbänden und Forschungseinrichtungen.

Die aufgeführten Anwendungsfälle und ihre Potenziale sollen als Anregung dienen, um FVU Ansätze zur Integration von KI zu bieten. Vorgegangen wurde dabei in drei Schritten:



Sammlung von KI-Anwendungsfällen

Mithilfe eines Concept Boards haben die Teilnehmenden in Einzelarbeit KI-Anwendungsfälle gesammelt und in die vier Anwendungsfelder „Netz- und Anlagenplanung“, „Netz- und Anlagenbetrieb“, „Instandhaltung und Wartung“ sowie „Vertrieb und Kundenschnittstelle“ einsortiert. So konnten die KI-Anwendungsfälle entlang der Wertschöpfungskette eines FVU eingeordnet werden. Ähnliche Gruppierungen sind in auch in vergleichbaren Veröffentlichungen zum Thema KI in der Energiewirtschaft zu finden.

Konkretisierung

Im Plenum wurden die Anwendungsfälle vorgestellt, zusammengeführt und anhand eines vereinfachten KI Use Case Canvas konkretisiert. Dabei wurden jeweils der Prozess, der Mehrwert und die benötigten Daten des Anwendungsfalls definiert.

Bewertung der Komplexität und des Potenzials

Für die auf diese Weise gesammelten Anwendungsfälle wurden gemeinsam Argumente für die Bewertung der Komplexität der Implementierung und des Betriebs sowie des ökonomischen und ökologischen Potenzials gesammelt und diskutiert. Anschließend konnten die Teilnehmenden jeden Anwendungsfall anonym auf einer Skala von 1 bis 10 nach jeweiliger Komplexität und jeweiligen Potenzialen bewerten.

2.2. KI-Anwendungsfälle in Wärmenetzen

Im Folgenden werden die zehn identifizierten KI-Anwendungsfälle mithilfe von Steckbriefen genauer beschrieben. Neben einer jeweiligen allgemeinen Beschreibung des Anwendungsfalls werden stichpunktartig die benötigten Daten genannt sowie die Argumente der Expertinnen und Experten bezüglich der Einschätzung zu Komplexität und Potenzial beschrieben.

Kursiv geschriebene Informationen wurden nachträglich zur Bewertung der KI-Anwendungsfälle hinzugefügt und sind bei der Bewertung nicht berücksichtigt worden. Diese Informationen dienen der Vollständigkeit der Publikation.

01. Langfristige betriebswirtschaftliche und technische Asset-Optimierung

Um wirtschaftlich zu operieren, müssen FVU die langfristige Rentabilität des Fernwärmenetzes sicherstellen. Dazu können die Effizienz, Lebensdauer und Leistungsfähigkeit von bestehenden Anlagen und Infrastrukturen optimiert sowie Szenarien entwickelt werden, um zukünftige Investitionsentscheidungen zu treffen. Bei diesem Anwendungsfall handelt es sich um einen eher übergeordneten Prozess, in den die Ergebnisse vieler spezialisierterer Prozesse (beispielsweise Netzausbauplanung, Wärmelastentwicklung, Entwicklung Kostenstrukturen etc.) einfließen.

Benötigte Daten:

Preisprognosen; Bedarfsprognosen; Investitionskosten für Assets; *spezifische Anlagendaten (Metainformationen wie Leistungen, Primärenergieträger etc.); Erzeugungsprognosen; Informationen zu Förderungen*

Komplexitäten:

Optimierungsalgorithmus; Gesamtbetrachtung zwischen Erzeugung und Netz; Modellierung aller Rahmenbedingungen (Förderungen), wächst mit dem Erzeugerportfolio des Anwenders

Potenziale:

Detaillierte Vollkostenanalysen für Investitionen; optimierte Investitionsentscheidungen; Mehrwert (*Handlungssicherheit bei Investitionsentscheidungen, zukünftige Wahl der Wärmeerzeugungstechnologien gemäß Netzlastentwicklung, optimierter Betrieb der Erzeuger*) durch frühzeitige Einbindung vieler Parameter

02. Optimierung Kundenanlage (Wirkung auf Primärseite)

Hohe Rücklauftemperaturen in einem Fernwärmenetz führen zu einer niedrigeren Systemeffizienz. Um die Rücklauftemperaturen zu reduzieren, können Kundenanlagen mithilfe von (KI-gestützten) Algorithmen optimiert werden, sodass sie präziser diejenige Wärmemenge abnehmen, die tatsächlich in den Kundenanlagen verbraucht wird (Vermeidung von Überversorgung). Dadurch werden die Rücklauftemperaturen der jeweiligen Kundenanlagen reduziert, was sich positiv auf die Rücklauftemperaturen des Fernwärmenetzes auswirkt.

Benötigte Daten:

HAST-Betriebsdaten (*Leistung, Volumenstrom, Temperaturen; hochaufgelöst und möglichst umfangreiche historische Daten*)

Komplexitäten:

Gute Datengrundlage muss vorhanden sein; Metainformationen über Kundenanlagen müssen vorhanden sein; Versorgungsverträge sehen eine Steuerung durch Betreiber nicht vor; abhängig von den Eigentumsverhältnissen der Kundenanlagen (Eingriff in die HAST möglicherweise unerwünscht)

Potenziale:

Spitzenlastreduktion; CO₂-Einsparung; *zahlt auf Senkung der Rücklauftemperaturen der einzelnen HAST und somit des gesamten Netzes ein, was die Gesamteffizienz des Fernwärmenetzes steigert*

03. Optimierung Kundenanlagen (Wirkung auf Sekundärseite)

Die Bereitstellung von Wärmeenergie in Gebäuden kann durch eine präzisere Fahrweise der Kundenanlagen optimiert werden. Deren Lebensdauer kann durch eine geringere Auslastung erhöht werden. So können für Kundinnen und Kunden Kosteneinsparungen realisiert werden, ohne Komfortverluste zu bedingen.

Benötigte Daten:


Betriebsdaten der Hausanschlussstationen; Gebäudesensordaten (beispielsweise der nachgelagerten Komponenten wie Heizkreise und Warmwasserbereitungen oder Raumtemperatursensoren)

Komplexitäten:

Daten (hochaufgelöst und möglichst umfangreiche historische Daten) von Sekundärseite benötigt, die durch zusätzliche Messtechnik erhoben werden müssen; Installation der Messtechnik an den richtigen Messpunkten gestaltet sich oft schwierig

Potenziale:

Verbesserung Effizienz Kundenanlage; Erhöhung der Versorgungssicherheit; Reduzierung Netzzücklauf-temperatur; CO_2 -Einsparung; Unterstützung bei Inbetriebnahme durch Handlungssicherheit; zählt auf Senkung der Netz-Rücklauf-temperaturen ein; durch rücklauf-temperaturbedingte Bepreisung könnte ein monetärer Mehrwert für Kunden entstehen



04. Optimierung des Netzbetriebs und der Netzhydraulik

Mittels einer KI-basierten Optimierung des Netzbetriebs und der Netzhydraulik kann Wärme präziser bereitgestellt und somit der Primärenergieeinsatz reduziert werden.

Benötigte Daten:


Technische Daten der Erzeuger; Totzeiten; Betriebsdaten (historisch & live); Druckflussmenge; Druckflussgeschwindigkeit; Druckverhältnisse; Fließdaten; Pumpendaten; Netztopologie


Komplexitäten:

Thermohydraulische Netzberechnung ohne hohe Sicherheitszuschläge; Erhebung Messdaten im Netz

Potenziale:

Senkung Wärmeverluste; CO_2 -Einsparung; Erhöhung der Anlageneffizienz; Einhaltung der technischen Anschlussbedingungen; besseres Druckmanagement; Reduktion des Pumpstroms; Entlastung des Betriebspersonals; Erkennung von Engpässen; hydraulische Optimierung; verbesserte Voraussetzungen für Netznachverdichtung; Einsparung Pumpstrom und Primärenergieverbrauch





05. Predictive Maintenance (Netzbetreiberseite)

Sämtliche Komponenten eines Fernwärmenetzes müssen aufgrund von Verschleiß regelmäßig gewartet oder ausgetauscht werden. Anstatt diese periodisch zu warten, können mithilfe von KI-basierten Prognosen die Ausfallwahrscheinlichkeit bzw. der Ausfallzeitpunkt eingegrenzt und somit der Zeitpunkt der Wartung präziser festgelegt bzw. die Anzahl der Wartungsarbeiten reduziert werden. Das Prognosemodell muss Abweichungen und Trends in den Daten erkennen und darauf basierend den Wartungszeitpunkt bestimmen. Kurzfristige Abweichungen, also Anomalien wie bei einem Rohrbruch, können jedoch nur reaktiv behandelt werden.

Benötigte Daten:

Referenzfälle; Sollzustand; aktuelle Betriebsdaten; Toleranzen; *Logdaten*; *Sensordaten*

Komplexitäten:

Identifikation von Anomalien gegebenenfalls schwierig; Lokalisierung von Rohrbrüchen gegebenenfalls sehr komplex (es werden viele Messinstrumente benötigt); sehr viele hochaufgelöste Daten benötigt; Parametersets bei Kundenanlagen ohne zusätzliche Daten der Sekundärseite nicht eindeutig interpretierbar; Prognosegüte bei HAST gegebenenfalls fraglich

Potenziale:

Reduktion von Personaleinsatz; Kostenreduktion; Verlängerung der Lebensdauer; positive nachgelagerte Auswirkungen auf den Netzbetrieb; Steigerung der Zuverlässigkeit

06. Predictive Maintenance (Kundenseite)

Der Ausfall von Kundenanlagen wird meist erst bemerkt, wenn bei den Kundinnen und Kunden keine Wärme mehr ankommt und die Raumtemperatur bereits außerhalb des Komfortbereichs liegt. Mithilfe von KI-basierten Prognosen von Ausfallwahrscheinlichkeit und Zeitpunkt auf Basis von sekundärseitigen Betriebsdaten (Temperaturen etc.) kann der Netzbetreiber bereits im Vorfeld darauf hinweisen, dass eine Kundenanlage gewartet werden sollte. Beispielsweise könnten Wärmeübertrager hinsichtlich ihrer Übertragungsleistung (Grädigkeit) analysiert werden, um eine rechtzeitige Wartung zu veranlassen.

Benötigte Daten:

Referenzfälle; Sollzustand; aktuelle Betriebsdaten; Toleranzen; *Logdaten*; *Sensordaten*

Komplexitäten:

Identifikation von Anomalien gegebenenfalls schwierig; sehr viele hochaufgelöste Daten benötigt; Daten von Sekundärseite benötigt; *aufwendige Installation von Messtechnik auf der Sekundärseite*

Potenziale:

Komforterhalt beim Kunden; Möglichkeit zum Angebot einer neuen Dienstleistung; Reduktion Kundenreklamationen, Abschätzung von Potenzial schwierig (neue Dienstleistung)

07. Frühzeitige Störungserkennung an Kundenanlagen (kurzfristig)

Bei Kundenanlagen kann es zu Störungen und Ausfällen kommen. Mittels KI-basierter Assistenzsysteme und entsprechender Sensorik können diese kurzfristig erkannt, verortet und behoben werden.

Benötigte Daten:

Betriebsdaten von Netz und Hausanschlussstationen

Komplexitäten:

Daten von Sekundärseite benötigt; Steuerung der Kundenanlagen durch Betreiber fraglich; *aufwendige Installation von Messtechnik auf der Sekundärseite*

Potenziale:

Einsparung von Fehlfahrten; Erhöhung der Kundenzufriedenheit; schnelle Störungsbearbeitung; Eingrenzung, ob Ausfälle primär- oder sekundärseitig bedingt sind

08. Kapazitätsmanagement Netz und Erzeugung

Der Umgang mit den Kapazitäten der Erzeugungsanlagen und des Netzes ist vor allem im Kontext der Ausbauplanung und des Vertriebs eine zentrale Herausforderung für Netzbetreiber. KI-basierte Tools können die Nutzung der vorhandenen Kapazitäten optimieren und beim Ausbau der Kapazitäten unterstützen.

Benötigte Daten:

Erzeugungs- und Anschlussdaten, Betriebsdaten

Komplexitäten:

Hoher Detailgrad der Datengrundlage benötigt

Potenziale:

Bessere Vertriebssteuerung, höherer Vertrieb, gezielter Ausbau, Kosteneinsparungen durch weniger Ausbau bzw. stärkere Nutzung vorhandener Kapazitäten

10. Energetisches Monitoring (und Abgleich von Richtlinien)

Fernwärmenetze zukünftiger Generationen mit vielen kleineren Erzeugungsanlagen und Prosumer-Strukturen können unübersichtlich werden, was die Komplexität des Monitorings eines Fernwärmenetzes erhöht. KI-basierte Tools können Transparenz über Verbräuche schaffen, um so Energiekennzahlen zu bilden und diese beispielsweise mit Förderrichtlinien abzugleichen.

Benötigte Daten:

Erzeugungsmix; kundenseitiger Energieverbrauch

Komplexitäten:

Starke Abhängigkeit von zukünftigen klimatischen Bedingungen mit hoher Unschärfe; *Anzahl Sensoren*

Potenziale:

Rechtssicherheit; Anschluss neuer Gebäude; Erfüllung von Grundbedingungen für Förderungen; Transparenzschaffung bei aktuellen Verbräuchen und potenzielle Entwicklung bis zum Ende des Verbrauchsjahres; Aufschluss über die voraussichtliche Einhaltung der Förderrichtlinien (kWh/m²a, CO₂-Emissionen, Energiemix)

09. Optimierung des Wärmeerzeugerbetriebs

Erzeugungsanlagen müssen entsprechend dem erwarteten Wärmebedarf gesteuert werden. Dabei sollte möglichst nur so viel Wärme erzeugt werden, wie sie auch verbraucht wird, ohne dabei in eine Unterversorgung zu geraten. Mittels KI-basierter Tools kann die benötigte Wärmemenge präziser ermittelt und die Erzeugungsanlagen somit effizienter gefahren werden. Zugleich kann durch vorausschauende Betriebsführung und Nutzung von Pufferkapazitäten die Wirtschaftlichkeit der Wärmeerzeugung beispielsweise durch strompreisorientierte Betriebsführung von BHKWs gesteigert werden.

Benötigte Daten:

Detaillierte Anlagendaten, Betriebsdaten der Erzeuger, RI-Daten (*Rohrleitung und Instrumentenfließschema*)

Komplexitäten:

Datenlage muss sehr gut sein, damit eine gute Netzlastprognose erstellt werden kann; Differenzierung zwischen energieeffizienter und wirtschaftlicher Betriebsweise; Strompreisdaten erforderlich (wenn KWK/WP mit enthalten sind und Strom verkauft wird); Metadaten zur Zusammensetzung der Wärmeerzeuger erforderlich (Art, Erlös- und Kostenfunktionen); Optimierungsalgorithmus für jede Erzeugerkonstellation

Potenziale:

Wirtschaftliche und technische Optimierung; *CO₂-Einsparung*; Einhaltung von Förderrichtlinien *bei neu errichteten und geförderten Wärmeerzeugungsanlagen, die beispielsweise den Nachweis der Einhaltung von Effizienzstandards erfordern*; Hebung von ungenutzten finanziellen Potenzialen durch vorausschauende, effiziente und gezielte Betriebsführung zu wirtschaftlich günstigsten Konditionen; gezielter Betrieb von BHKW zum gesteigerten Stromverkauf oder Nutzung von Pufferspeicherkapazitäten zur Überbrückung von niedrigen Stromvergütungsphasen

2.3. Komplexität und Potenzial der KI-Anwendungsfälle

Die Bewertung der KI-Anwendungsfälle ist eine auf Meinungen der Expertinnen und Experten basierende Indikation. Das tatsächliche Potenzial sowie die Komplexität werden auf individueller Anwenderebene von vielen verschiedenen Faktoren beeinflusst. Bei den Ergebnissen handelt es sich um Mittelwerte aus abgegebenen Einschätzungen. Die Standardabweichungen der einzelnen Datenpunkte beläuft sich auf etwa zwei Bewertungspunkte pro Datenpunkt. Eine tabellarische Aufstellung der Datenwerte befindet sich im Anhang. Die Ergebnisse spiegeln logischerweise nicht zwangsläufig die Meinung einzelner Expertinnen oder Experten wider.

Aufgrund der Methodik und des gleichmäßig auf die Stakeholdergruppen verteilten Teilnehmendenkreises bieten die Ergebnisse dennoch eine wertvolle Indikation dafür, welche KI-Anwendungsfälle tendenziell einen größeren Nettonutzen liefern könnten. Die Argumentation zur Einordnung der Anwendungsfälle lässt sich aus den Steckbriefen ablesen. Ein Abgleich dieser Daten mit den Voraussetzungen und Gegebenheiten eines individuellen Unternehmens ermöglicht es, die Ergebnisse auch auf individueller Ebene nutzbar zu machen.

Gesammelte Anwendungsfälle für KI im Fernwärmenetz¹

- 1 Langfristige betriebswirtschaftliche und technische Asset-Optimierung
- 2 Optimierung Kundenanlage (Wirkung auf Primärseite)
- 3 Optimierung Kundenanlage (Wirkung auf Sekundärseite)
- 4 Optimierung des Netzbetriebs und der Netzhydraulik
- 5 Predictive Maintenance (Netzbetreiberseite)
- 6 Predictive Maintenance (Kundenseite)
- 7 Frühzeitige Störungserkennung an Kundenanlagen (kurzfristig)
- 8 Kapazitätsmanagement Netz und Erzeugung
- 9 Optimierung des Wärmeerzeugerbetriebs
- 10 Energetisches Monitoring (und Abgleich von Richtlinien)

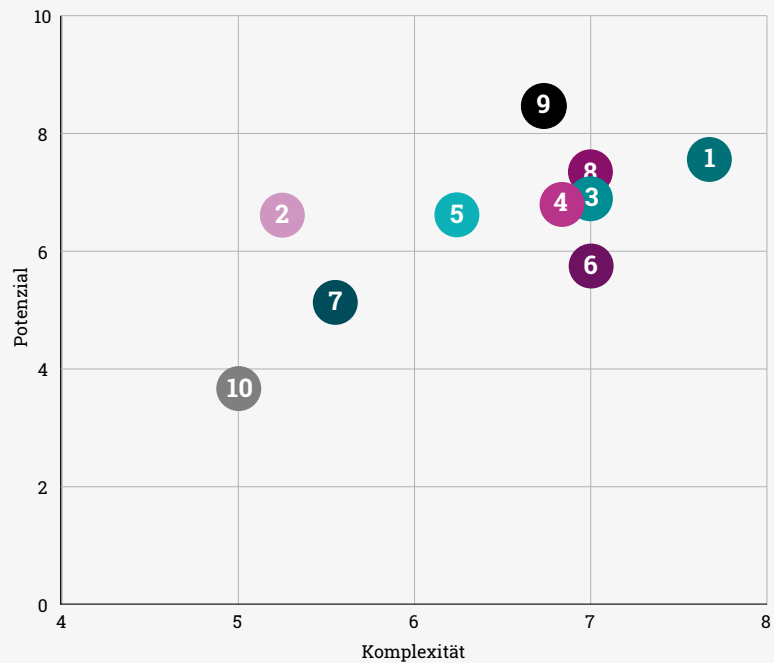



Abbildung 2: KI-Anwendungsfälle. Quelle: Eigene Darstellung, dena, 2024

Bei der Interpretation der Ergebnisse ist darauf zu achten, dass die *low hanging fruits*, also die Anwendungsfälle mit dem höchsten Potenzial und der niedrigsten Komplexität, in den linken oberen Bereich des Graphen tendieren. Als vielversprechend können somit die Anwendungsfälle *Optimierung des Wärmeerzeugerbetriebs* und *Optimierung Kundenanlage (Wirkung auf Primärseite)* identifiziert werden. Die meisten Anwendungsfälle ordnen sich in einem ausgeglichenen Verhältnis aus Potenzial und Komplexität bei einem eher höheren Wertebereich ein. Die meisten Anwendungsfälle sind demnach eher komplex, gehen aber auch mit einem eher hohen Potenzial einher. Lediglich bei den Anwendungsfällen *Energetisches Monitoring (und Abgleich von Richtlinien)* und *Predictive Maintenance (Kundenseite)* überwiegt die Komplexität das Potenzial.

Die Ergebnisse dieses Kapitels wurden in Kollaboration mit unter anderem folgenden Institutionen erarbeitet:

- Danfoss GmbH
- Fraunhofer-Institut für Energiewirtschaft und Energiesystemtechnik IEE
- Gradyent GmbH
- items GmbH & Co. KG
- Kelvin Green GmbH
- MoxyByte GmbH
- RheinEnergie AG
- Samson KT-Elektronik GmbH
- Stadtwerke Pforzheim GmbH & Co. KG
- swb Erzeugung AG & Co. KG
- wesernetz Bremen GmbH
- Zentur.io GmbH





3.

Projektblaupause

In diesem Kapitel des Leitfadens wird eine Projektblaupause für KI-Projekte bei FVU vorgestellt, basierend auf dem etablierten CRISP-DM-Modell. Dieses Rahmenwerk bietet einen systematischen Ansatz zur Durchführung von Datenanalyseprojekten und wird ergänzt durch bewährte Praktiken in der KI-Projektentwicklung. Das Ziel ist es, Betreibern von Fernwärmenetzen eine strukturierte Vorgehensweise für die Implementierung von KI-Lösungen zu bieten. Ergänzend zu CRISP-DM können weitere Ansätze wie agile Methoden für iteratives Projektmanagement in Betracht gezogen werden, um Flexibilität im Projektverlauf zu gewährleisten und eine kontinuierliche Anpassung an neue Erkenntnisse und Anforderungen zu ermöglichen.

Das CRISP-DM-Modell (siehe Abbildung 3) besteht aus sechs Phasen: Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation und Deployment. Diese Phasen bieten einen umfassenden Rahmen für die Planung und Durchführung von Datenanalyseprojekten. **Business Understanding** zielt darauf ab, die Geschäftsziele zu definieren und die Projektanforderungen aus einer Geschäftsperspektive zu klären. **Data Understanding** umfasst die Erfassung und Untersuchung der relevanten Daten. In der Phase Data Preparation werden die Daten für die Modellierung aufbereitet. Die **Modeling-Phase** beinhaltet die Auswahl und Anwendung geeigneter Modellierungstechniken aus dem Bereich der Datenwissenschaft. Die Evaluation bewertet die Modellleistung und überprüft, ob die Geschäftsziele erreicht wurden. Schließ-

lich umfasst die Deployment-Phase die Implementierung des Modells in der Praxis und die daran anschließende produktive Nutzung. In der Projektblaupause wird das Rahmenwerk noch um die Phase des laufenden Betriebs ergänzt. In dieser Phase wird das KI-Modell überwacht, gewartet und aktualisiert.

Die vorgestellten Schritte werden jeweils mit Beispielen aus dem im Projekt „KI in Fernwärme“ umgesetzten Anwendungsbeispiel der Optimierung des Wärmeerzeugerbetriebs (vgl. Kapitel 2.2 KI-Anwendungsfälle in Fernwärmenetzen, Anwendungsfall 9) angereichert. Hierbei fokussiert sich die Projektblaupause auf den ersten Teil, die durch maschinelles Lernen erzeugte Lastprognose. Der im zweiten Teil durch lineare Optimierung erzeugte Einsatzplan wird in den Hintergrund gerückt. Zur Entwicklung der Lastprognose werden alle in der Blaupause erwähnten Schritte notwendig und können daran skizziert werden. Die Umsetzung des zweiten Teils würde die Schritte entsprechend wiederholen.



Experten-Tipp: Open-Source

Ermutigen Sie zur Nutzung von Community-Wissen und Open-Source-Ressourcen. Viele Herausforderungen in KI-Projekten sind nicht einzigartig und können durch bereits vorhandene Lösungen und Best Practices adressiert werden.




Abbildung 3: CRISP-DM Prozess-Diagramm. Quelle: Eigene Darstellung in Anlehnung an Wirth, 2000

Die Implementierung von KI-Technologien bietet für FVU die Möglichkeit, Effizienz zu steigern, Kosten zu senken und die Servicequalität zu erhöhen. Eine strukturierte Herangehensweise ist dabei essenziell. In diesem Leitfaden erhalten Sie die nötigen Werkzeuge und Anleitungen, um eigene KI-Projekte erfolgreich durchzuführen. Die technischen Details werden in dieser Publikation aufgrund ihrer Vielschichtigkeit nur oberflächlich skizziert. Daher ersetzt dieser Leitfaden nicht die Notwendigkeit, eine Expertin oder einen Experten aus dem Bereich Data-Science oder Künstliche Intelligenz zu konsultieren.

Mit dieser Einführung möchten wir Ihnen einen Überblick über die Struktur und den Inhalt dieses Kapitels geben, sodass Sie in der Lage sind, die einzelnen Schritte des CRISP-DM-Modells zu verstehen und auf Ihre eigenen Projekte anzuwenden. Ziel ist es, Ihnen eine praxisorientierte und gleichzeitig theoretisch fundierte Anleitung zur Implementierung von KI-Lösungen in Fernwärmenetzen zu bieten.

3.1. Business Understanding: Zielsetzung definieren und Geschäftsverständnis entwickeln

Für die erfolgreiche Umsetzung eines KI-Anwendungsfalls im Fernwärmenetz ist eine gründliche Vorbereitung unerlässlich. Diese umfasst vor allem die Auseinandersetzung mit den potenziellen Auswirkungen auf das Geschäft des FVU. Eine klare Definition der Projektziele und Anforderungen aus einer Geschäftsperspektive bildet die Grundlage für den Erfolg.

Zunächst ist es wichtig, die Ziele des Projekts genau zu klären. Was soll durch den Einsatz von KI erreicht werden? Ein präzise formuliertes Ziel hilft nicht nur bei der späteren Umsetzung, sondern auch bei der Bewertung des Projekterfolgs. Fragen Sie Domänenexpertinnen und -experten innerhalb des Unternehmens, um ein tiefes Verständnis der aktuellen Prozesse zu erlangen und zu erfahren, welche Daten derzeit genutzt werden, um die Arbeit zu verrichten.

Zielgruppe und Prozessverbesserung

Bei der Definition eines Anwendungsfalls ist es essenziell, die Zielgruppe zu bestimmen, für die der Anwendungsfall gedacht ist. Ein fiktives Beispiel könnte ein Netzmeister sein, der für die Überwachung und Steuerung des Fernwärmenetzes verantwortlich ist. Alternativ könnte es sich um die Leitwarte handeln, die die operative Kontrolle und Planung der Energieerzeugung und -verteilung innehat. Ein weiterer möglicher „Kunde“ ist der Endkunde, der die Wärmeenergie nutzt.

Für die Kundinnen und Kunden muss jeweils untersucht werden, welche spezifischen Tätigkeiten oder Prozesse durch den Einsatz von KI verbessert werden können. Beim Netzmeister könnte dies die Optimierung der Netzlastverteilung sein, wodurch Betriebskosten gesenkt und die Effizienz sowie die Zuverlässigkeit gesteigert werden. Für die Leitwarte könnte die Einführung eines KI-gestützten Vorhersagemodells die Planung und Steuerung der Kraftwerkseinsätze verbessern, was zu einer effizienteren Nutzung der Energiequellen führt. Beim Endkunden könnte der Fokus auf der Verbesserung der Versorgungssicherheit und der Erhöhung der Zufriedenheit durch eine stabile und verlässliche Wärmeversorgung liegen.

Durch die genaue Analyse der Bedürfnisse und Herausforderungen der jeweiligen Zielgruppe lässt sich der Mehrwert eines KI-Anwendungsfalls klarer definieren und gezielt optimieren. Diese Vorgehensweise stellt sicher, dass der Anwendungsfall nicht nur technisch umsetzbar, sondern auch praktisch relevant und wirtschaftlich sinnvoll ist.

Messbaren Mehrwert ermitteln

Ein weiterer entscheidender Schritt ist die Identifikation des genauen Mehrwerts, den das Projekt liefern soll, und die Möglichkeit, diesen Mehrwert zu quantifizieren. Welche Key Performance Indicators (KPI) sollen durch das Projekt optimiert werden?

Typische KPI könnten die Einsparung von Energieträgern (eingesparte kWh Gas oder Strom im Vergleich zu einem Referenzzeitraum), die Erhöhung der Kundenzufriedenheit (Messung durch Kundenbefragung, Zählen von Kundenkontakten an der Supporthotline) oder die Verbesserung der Versorgungssicherheit (Ausfälle oder Mangelmeldungen zählen und vergleichen) sein. Je klarer diese Messgrößen vorab definiert werden, desto besser kann später im Betrieb evaluiert werden, ob die Umsetzung erfolgreich war.

Um diese Punkte zu erarbeiten, empfiehlt sich die Durchführung von interaktiven Workshops. In diesem Rahmen können verschiedene Anwendungsfälle diskutiert und deren potenzielle Auswirkungen analysiert werden. Techniken aus



Experten-Tipp: Stakeholder-Einbindung

Binden Sie alle relevanten Stakeholder, wie Betriebsleiterinnen und Betriebsleiter, IT-Abteilung und Endnutzerinnen und Endnutzer, frühzeitig in das Projekt ein. Dies sichert Unterstützung und hilft, Anforderungen klar zu definieren sowie Missverständnisse zu vermeiden. Für die Integration in die bestehenden IT-Systeme und Prozesse sollten Sie die IT-Abteilung von Anfang an einbeziehen, um eine reibungslose Implementierung und den späteren Einsatz in Test- und Produktionsumgebungen zu gewährleisten.

dem Bereich des Design-Thinking eignen sich sehr gut, um mit den Teilnehmerinnen und Teilnehmern verschiedene Anwendungsfälle zu finden. Durch die konkrete Beschreibung des umzusetzenden Anwendungsfalls wird der Grundstein für die nachfolgenden Schritte wie Data Understanding, Modellierung und Evaluierung gelegt.

Zusammengefasst lässt sich sagen, dass eine gründliche Auseinandersetzung mit den Geschäftszielen und -anforderungen sowie eine klare Zieldefinition entscheidend sind für den Erfolg eines KI-Projekts im Fernwärmenetz. Nur durch ein tiefes Geschäftsverständnis und die präzise Formulierung der Ziele kann sichergestellt werden, dass die späteren Implementierungs- und Evaluierungsschritte effektiv durchgeführt werden können.

Beschreibung der intelligenten Erzeugereinsatzplanung (IEE)

Die intelligente Erzeugereinsatzplanung wird in der Leitwarte des Fernwärmenetzbetreibers integriert, wo sämtliche Netzdaten und die Netzsteuerung zusammenlaufen. Das System bietet die folgenden Mehrwerte:

- **Optimierung des Netzbetriebs hinsichtlich** verschiedener KPI wie CO₂-Emissionen, Verschleiß, Kosten, Regelleistungsvermarktung oder anderer Kriterien, die während der Entwicklungsphase definiert werden
- **Vorausschauende Fahrplanbestimmung** durch Prognosemodelle, die zukünftige Lasten und Erzeugungsbedarfe vorhersagen
- **Reduzierung des Energieeinsatzes** durch korrekte Lastbestimmung für den kommenden Zeitraum

Im Gegensatz zur bisherigen, auf Erfahrungswerten basierenden Fahrweise der Erzeugungsanlagen ermöglicht das neue System eine algorithmisch gesteuerte Wärmeerzeugung. Dadurch kann proaktiv und dynamisch auf Änderungen des Netzzustandes reagiert werden.



Beispiel: Ziele der Intelligenten Erzeugereinsatzplanung (IEE)

Die Zielsetzung des Projekts ist die Einführung einer intelligenten Erzeugereinsatzplanung, die als Assistenzsystem für den Fernwärmenetzbetreiber fungiert. Dieses System kann nicht nur reaktiv auf Änderungen im Netz reagieren, sondern auch proaktiv die optimale Erzeugerwahl vorhersagen und somit die Einsatzplanung und Regelungsstrategie nachhaltig verbessern.

Beispiel: Bewertung des Anwendungsfalls IEE

Prognosegenauigkeit: Vergleich des vorhergesagten Lastgangs mit dem tatsächlich eingetretenen Lastgang
Kostenreduktion: Überprüfung, ob die Wärmegestehungskosten gesenkt werden konnten und die Strompreisschwankungen optimal ausgenutzt wurden.

CO₂-Emissionen: Messung des ausgestoßenen CO₂ in Kilogramm und Vergleich mit Referenzzeitraum.

3.2. Data Understanding: Verfügbarkeit von Daten prüfen und Datenexploration

Die Identifizierung und Nutzung geeigneter Datenquellen ist ein wesentlicher Bestandteil eines erfolgreichen KI-Projekts. Daten können aus einer Vielzahl von Quellen stammen und unterschiedliche Formate, zeitliche Auflösungen, Zeiträume und Qualitätsniveaus aufweisen. Diese Diversität stellt sowohl eine Herausforderung als auch eine Chance dar, da sie umfassende Einblicke ermöglicht, aber auch eine sorgfältige Datenvorbereitung erfordert.

Quellen, Formate und Qualität

Daten aus verschiedenen Quellen können in unterschiedlichen Formaten vorliegen, beispielsweise als CSV-Dateien, SQL-Datenbanken, JSON-Datenstrukturen oder in proprietären Formaten. Ebenso variiert die Auflösung und Granularität der Daten: Während Sensordaten oft in hoher zeitlicher Auflösung (Sekunden oder Minuten) vorliegen, können andere Datenquellen, wie beispielsweise Zählerstände, nur in täglichen oder monatlichen Intervallen verfügbar sein. Weiterhin können Datensätze unvollständig sein. So könnte beispielsweise der Leistungsdatensatz aller HAST unvollständig sein, da möglicherweise noch nicht alle HAST mit DFÜ-Technik ausgestattet wurden. Es kann im Projekt notwendig sein, Daten auch manuell zu erheben, um diese später für das Training des maschinellen Lernmodells zu verwenden.

Die Qualität der Daten ist ein weiterer entscheidender Faktor. Es können Fehler, Ausreißer oder fehlende Werte in den Daten vorhanden sein, die die Modellierung und Analyse beeinträchtigen. Eine gründliche Überprüfung und Bereinigung der Daten ist daher unerlässlich, um sicherzustellen, dass die Daten für die nachfolgenden Schritte geeignet sind. Hiermit werden wir uns in diesem Kapitel gleich näher beschäftigen.

Ein weiterer wichtiger Aspekt bei der Nutzung von Datenquellen sind rechtliche und lizenztechnische Überlegungen. Einige Datenquellen, wie beispielsweise Markt- oder Preisdaten von Strombörsen, können lizenzpflichtig sein. Es ist notwendig, vor der Nutzung solcher Daten die entsprechenden Lizenzen zu erwerben und sicherzustellen, dass die Nutzung den rechtlichen Rahmenbedingungen entspricht.

Ebenso müssen Datenschutzbestimmungen beachtet werden, insbesondere wenn personenbezogene Daten verarbeitet werden. Es ist sicherzustellen, dass alle gesetzlichen Anforderungen, wie die Datenschutz-Grundverordnung (DSGVO) in der EU, eingehalten werden. Dies umfasst die Anonymisierung oder Pseudonymisierung von Daten sowie die Einholung von Einwilligungen der betroffenen Personen, falls erforderlich.

Die explorative Datenanalyse (EDA) ist ein entscheidender Schritt in der Entwicklung von KI-Modellen. Sie dient dazu, ein

tiefes Verständnis für die verfügbaren Daten zu erlangen und die Grundlage für die nachfolgende Modellierung zu legen. Ziel der EDA ist es, Muster, Zusammenhänge und Auffälligkeiten in den Daten zu entdecken, die für die Modellbildung relevant sind.

Datenverständnis

Um ein umfassendes Datenverständnis zu entwickeln, ist es wichtig, die relevanten Datenquellen zu identifizieren und die benötigten Daten zu erheben. Die Verfügbarkeit und Qualität der Daten spielt eine entscheidende Rolle für den Erfolg des Projekts. Es muss sichergestellt werden, dass die relevanten Daten für das Training des Modells in ausreichender Menge und Qualität verfügbar sind.

Expertinnen und Experten innerhalb des Unternehmens sollten konsultiert werden, um zu verstehen, welche Daten aktuell zur Rate gezogen werden und wie diese Daten erhoben werden. Sensordaten, Zählerdaten und weitere betriebliche Daten sind oft entscheidend für die Modellierung des Wärmebedarfs.



Beispiel: Korrelation und Korrelationsmatrix

Die Korrelation ist ein statistisches Maß, das die Stärke und Richtung einer linearen Beziehung zwischen zwei Variablen angibt. Der Korrelationskoeffizient, oft als Pearson-Korrelationskoeffizient bezeichnet, kann Werte zwischen -1 und 1 annehmen. Ein Wert von 1 bedeutet eine perfekte positive lineare Beziehung, -1 eine perfekte negative lineare Beziehung und 0 bedeutet keine lineare Beziehung.


Eine Korrelationsmatrix ist ein tabellarisches Werkzeug, das die paarweisen Korrelationen zwischen mehreren Variablen darstellt. Jede Zelle in der Matrix zeigt den Korrelationskoeffizienten zwischen zwei Variablen an. Eine Korrelationsmatrix ist besonders nützlich, um Muster und Beziehungen in großen Datensätzen zu erkennen und zu visualisieren. In der Datenanalyse wird sie häufig verwendet, um zu bestimmen, welche Variablen stark miteinander in Beziehung stehen und welche Variablen möglicherweise redundant sind.

Datenexploration

Die Datenexploration ist ein integraler Bestandteil der Datenanalyse und umfasst die Untersuchung der Daten, um Muster und Auffälligkeiten zu identifizieren. Dazu gehört die Durchführung von deskriptiven Analysen wie die Berechnung von Mittelwerten, Medianen, Standardabweichungen und anderen statistischen Kennzahlen. Diese Analysen geben Aufschluss über die grundlegenden Eigenschaften der Daten und helfen, ein erstes Gefühl für die Daten zu bekommen.

Die EDA umfasst verschiedene Methoden und Techniken, um die Struktur und Verteilung der Daten zu analysieren. Dazu gehören deskriptive Statistiken, visuelle Darstellungen wie Histogramme, Boxplots und Streudiagramme sowie die Identifikation von Ausreißern und fehlenden Werten. Histogramme können beispielsweise verwendet werden, um die Verteilung einzelner Variablen zu analysieren. Zeitreihenanalysen sind besonders nützlich, um Trends und saisonale Muster in den Daten zu identifizieren. Durch diese Analyse können wichtige Erkenntnisse gewonnen werden, die dabei helfen, die Datenqualität zu bewerten und geeignete Transformationsschritte für die Modellierung abzuleiten.

Ein Beispiel aus dem Fernwärmebereich könnte die Visualisierung der täglichen Wärmelast über mehrere Jahre hinweg sein. Dabei könnten saisonale Muster, Wochentag-Effekte oder Trends im Zeitverlauf identifiziert werden. Solche Erkenntnisse sind wertvoll, um die Modellparameter entsprechend anzupassen und die Vorhersagegenauigkeit zu erhöhen.²



² Multikollinearität: Multikollinearität liegt vor, wenn zwei oder mehr erklärende Variablen eine sehr starke Korrelation miteinander haben.

B

Beispiel: Beschreibung der Korrelationsmatrix für Kraftwerksdaten

Die nachfolgende Grafik zeigt die Korrelationsmatrix, die aus den Daten unseres prototypisch umgesetzten Anwendungs-falls erstellt wurde. Hierbei wurden die Leistungsdaten eines Heizkraftwerkes mit verschiedenen Umweltdaten wie Außentemperatur, Sonneneinstrahlung, Windgeschwindigkeit, Luftdruck, Niederschlagsmenge und relativer Luftfeuchtigkeit kombiniert.




Abbildung 4: Korrelationsmatrix für Kraftwerksdaten.
Quelle: Eigene Darstellung, dena, 2024

In der Matrix sind die Korrelationskoeffizienten durch Farbskalen visualisiert: Positive Korrelationen werden in Rot und negative Korrelationen in Blau dargestellt. Die Intensität der Farbe gibt die Stärke der Korrelation an.

Leistung HW (Heizwerk) zeigt eine starke negative Korrelation (-0,63) zur Außentemperatur, was bedeutet, dass die Leistung des Heizwerks steigt, wenn die Außentemperatur sinkt. Dies ist logisch, da bei kälterem Wetter mehr Heizleistung benötigt wird.

Leistung BHKW (Blockheizkraftwerk) weist eine negative Korrelation (-0,42) zur Leistung HW auf, was bedeutet, dass beide Wärmeerzeuger nicht häufig parallel betrieben werden.

Die **Außentemperatur** zeigt eine moderate positive Korrelation (0,36) zur Sonneneinstrahlung und eine starke negative Korrelation (-0,62) zur relativen Luftfeuchtigkeit. Dies deutet darauf hin, dass sonnigere Tage tendenziell wärmer und trockener sind.

Windgeschwindigkeit, Luftdruck und **Niederschlagsmenge** zeigen geringere Korrelationen mit den anderen Variablen, was darauf hindeutet, dass sie in diesem spezifischen Anwendungsfall weniger stark mit der Heizwerksleistung oder den anderen Umweltdaten verbunden sind.

Die Analyse dieser Matrix hilft, ein besseres Verständnis der Beziehungen zwischen den verschiedenen Variablen zu entwickeln. Dies ist besonders nützlich bei der Modellierung, da es ermöglicht, relevante Prädiktoren für die Vorhersage der Heizwerksleistung zu identifizieren und potenzielle multikollineare Variablen zu erkennen, die die Modelleleistung beeinträchtigen könnten.

Multikollinearität tritt auf, wenn zwei oder mehr unabhängige Variablen in einem Modell stark miteinander korrelieren, das heißt, sie liefern ähnliche Informationen. Dies kann problematisch sein, da es die Stabilität und Interpretierbarkeit von Modellen beeinträchtigen kann. In der Korrelationsmatrix lässt sich dies erkennen, wenn mehrere Variablen hohe Korrelationswerte untereinander aufweisen. Bei multikollinearen Variablen kann das Modell Schwierigkeiten haben, den Einfluss jeder einzelnen Variable präzise zu schätzen, was die Vorhersagegenauigkeit verschlechtert. Daher ist es wichtig, potenziell multikollineare Variablen zu identifizieren und gegebenenfalls zu eliminieren oder zu transformieren.

Durch die Kombination und Analyse dieser Daten können fundierte Entscheidungen getroffen werden, die zu einer effizienteren Betriebsleitung des Heizkraftwerks führen. Die Korrelationsmatrix ist somit ein wertvolles Werkzeug, um die komplexen Zusammenhänge in den Daten zu visualisieren und besser zu verstehen.

Datenvorbereitung

Nach der Datenexploration folgt die Datenvorbereitung, die sich auf die Auswahl, Bereinigung und Formatierung der Daten konzentriert. Dieser Schritt ist entscheidend, um sicherzustellen, dass die Daten für die Modellierung geeignet sind. Dazu gehört die Behandlung fehlender Werte, die Bereinigung von Ausreißern und die Normalisierung der Daten.

Normalisierung ist ein wichtiger Schritt in der Datenvorbereitung, der sicherstellt, dass alle Variablen im Datensatz auf einem ähnlichen Wertebereich liegen. Bei der Normalisierung werden die Daten skaliert, sodass sie innerhalb eines bestimmten Bereichs (zum Beispiel zwischen 0 und 1) liegen. Dies ist besonders wichtig, wenn Modelle wie neuronale Netze oder distanzbasierte Algorithmen (wie k-Nearest Neighbor) verwendet werden, da diese Modelle empfindlich auf unterschiedlich skalierte Daten reagieren. Ohne Normalisierung könnten Merkmale mit größeren Wertebereichen das Modell dominieren und zu Verzerrungen in den Vorhersagen führen.

In der Phase der Datenvorbereitung wird auch entschieden, welche Daten in das Modell einfließen sollen. Hierbei wird die Relevanz der einzelnen Variablen geprüft und gegebenenfalls neue, abgeleitete Variablen erstellt. Beispiele für neue Merkmale könnten aggregierte Werte wie Durchschnittstemperaturen oder spezifische Indikatoren für besondere Wetterbedingungen sein. In einigen Fällen kann es sinnvoll sein, kontinuierliche Merkmale zu diskretisieren, also in Kategorien zu unterteilen, um bestimmte Muster besser erkennbar zu machen.



Beispiel: Abgeleitetes Merkmal Wochentag

Ein wichtiges abgeleitetes Merkmal aus den Zeitreihen der Kraftwerksdaten ist der Wochentag. Durch die Extraktion des Wochentags aus einem Zeitstempel können Muster im Energieverbrauch erkannt werden, die sich an bestimmten Tagen wiederholen. Zusätzlich kann ein Merkmal wie „ist Wochenende“ generiert werden, um zu identifizieren, ob ein Ereignis am Wochenende stattfindet. Diese Informationen sind hilfreich, um Unterschiede im Verbrauchsverhalten zwischen Wochentagen und Wochenenden zu analysieren und die Modelle entsprechend zu optimieren.



Experten-Tipp: Dokumentation

Dokumentieren Sie die Schritte zur Datenbereinigung sorgfältig und automatisieren Sie diese so umfassend wie möglich. Dies hilft später bei der Wartung des Systems. Verschiedene Tools können hierbei unterstützen.

3.3. Data Preparation: Datenverarbeitung und ETL-Pipelines

Nach einer umfassenden Analyse der Daten folgt die schrittweise Verarbeitung. Unterschiedliche Quellen und Formate müssen verarbeitet werden, um sie im nachfolgenden Schritt, der Modellierung, nutzen zu können.

ETL steht für Extract, Transform, Load und bezeichnet einen Prozess in der Datenverarbeitung, der aus drei Hauptschritten besteht: Datenextraktion, Datenumwandlung und Datenladung. Eine ETL-Pipeline automatisiert diesen Prozess und stellt sicher, dass die Daten aus verschiedenen Quellen gesammelt, in ein für die Analyse geeignetes Format umgewandelt und in ein Zielsystem geladen werden.

Extract (Extraktion)

In der Extraktionsphase werden Daten aus verschiedenen Quellen wie Datenbanken, APIs, CSV-Dateien oder anderen Datenformaten gesammelt. Ziel ist es, die benötigten Daten in ihrer Rohform zu sammeln, um sie für die weitere Verarbeitung verfügbar zu machen. Dieser Schritt kann die Integration unterschiedlichster Datenformate und -strukturen umfassen.

Transform (Transformation)

Die Transformationsphase beinhaltet die Umwandlung der extrahierten Rohdaten in ein geeignetes Format für die Analyse. Dies kann das Bereinigen, Filtern, Normalisieren, Aggregieren oder Anreichern der Daten umfassen. Transformationsschritte können auch komplexe Berechnungen und Datenumformungen beinhalten, um sicherzustellen, dass die Daten konsistent und nutzbar sind.

Load (Ladung)

In der Ladungsphase werden die transformierten Daten in ein Zielsystem geladen, wie beispielsweise ein Data Warehouse, eine Datenbank oder ein Data Lake. Dies ermöglicht den Endnutzenden, auf die bereinigten und konsistenten Daten für Analysen und Berichte zuzugreifen.

Vorteile von ETL-Pipelines

ETL-Pipelines bieten mehrere Vorteile:

- **Automatisierung und Effizienz:** Durch die Automatisierung des ETL-Prozesses wird der manuelle Aufwand reduziert und die Effizienz gesteigert. Daten können in regelmäßigen Intervallen oder in Echtzeit verarbeitet werden, was eine kontinuierliche Aktualisierung und Verfügbarkeit der Daten gewährleistet.
- **Konsistenz und Qualität:** ETL-Pipelines stellen sicher, dass die Daten in einem konsistenten Format vorliegen und den Qualitätsanforderungen entsprechen. Fehler und Inkonsistenzen in den Rohdaten werden in der Transformationsphase behoben, was die Zuverlässigkeit der Daten verbessert.

- **Datenintegration:** ETL-Pipelines ermöglichen die Integration von Daten aus unterschiedlichen Quellen. Dies erleichtert es, umfassende Datensätze zu erstellen, die für tiefgehende Analysen und fundierte Entscheidungsfindungen genutzt werden können.
- **Skalierbarkeit:** ETL-Pipelines sind skalierbar und können große Datenmengen verarbeiten. Dies ist besonders wichtig für Unternehmen, die kontinuierlich wachsende Datenmengen bewältigen müssen.
- **Flexibilität:** ETL-Pipelines können an die spezifischen Anforderungen eines Unternehmens angepasst werden. Sie bieten die Flexibilität, neue Datenquellen zu integrieren und bestehende Prozesse zu erweitern oder anzupassen.

Ein Beispiel für die Anwendung einer ETL-Pipeline im Kontext eines FVU könnte die Integration von Sensordaten, Zählerdaten und Umweltdaten sein. Die Daten werden aus den jeweiligen Quellen extrahiert, bereinigt und in eine zentrale moderne Datenbank geladen. Dort können sie für die Erstellung von Lastprognosen und die Optimierung der Betriebsführung genutzt werden.

Insgesamt tragen ETL-Pipelines dazu bei, dass Unternehmen ihre Daten effizient und effektiv nutzen können, um wertvolle Erkenntnisse zu gewinnen und fundierte Entscheidungen zu treffen.

Abbildung 5 zeigt die unterschiedlichen Datenquellen aus dem realisierten Projekt inklusive des verwendeten Datenformats und der zeitlichen Auflösung.




Abbildung 5: Zusammenführung unterschiedlicher Datenquellen, -typen und Schnittstellen. Quelle: Eigene Darstellung, dena, 2024

Die ETL-Pipeline für das Projekt „KI in Fernwärme“ umfasst die in Abbildung 5 aufgeführten Datenquellen und Prozesse. Die folgende Beschreibung erläutert die einzelnen Schritte dieser Prozesse:

Historische Betriebsdaten

Die historischen Betriebsdaten (beispielsweise Zählerstände, Leistungen und Vor- bzw. Rücklauftemperaturen) der einzelnen Kraftwerke im Fernwärmenetz wurden im CSV-Format geliefert. Diese initialen Datensätze wurden manuell übertragen und einmalig beim Projektstart in das Datenbanksystem importiert und gespeichert. Dieser Schritt stellt sicher, dass alle historischen Daten für die Analyse verfügbar sind.

Laufende Betriebsdaten

Die laufenden Betriebsdaten werden als E-Mail-Anhang im CSV-Format verschickt. Ein automatisiertes System überprüft kontinuierlich den Posteingang, liest die E-Mails aus, extrahiert die Anhänge und konvertiert sie in das erforderliche Format, um sie in die zentrale Datenbank zu übertragen. Dieser Prozess ermöglicht die kontinuierliche Aktualisierung der Betriebsdaten.

Netzdaten (Live)

Livedaten von Zählern an den Kundenstationen werden über die LoRa-Funktechnologie an ein zentrales System gesendet. Diese Daten können über eine API-Schnittstelle im JSON-Format zyklisch abgefragt und in die Datenbank importiert werden. Dadurch wird nahezu eine Echtzeit-Überwachung der Netzdaten gewährleistet.

Wetterdaten

Umweltdaten für das KI-Projekt werden vom Deutschen Wetterdienst (DWD) bezogen. Diese Daten stehen über einen FTP-Server zum Download bereit und werden periodisch abgefragt. Nach dem Download werden die Daten in die zentrale Datenbank integriert, um sie für die Analyse und Modellierung verfügbar zu machen.

Durch diese ETL-Pipeline werden alle relevanten Datenquellen integriert und in einem zentralen System gespeichert, wodurch eine umfassende aktuelle Datenbasis für die Analyse und Modellierung geschaffen wird. Diese strukturierte Herangehensweise stellt sicher, dass die Datenqualität hoch bleibt und die Daten kontinuierlich für die Entscheidungsfindung und Optimierung der Fernwärmenetze zur Verfügung stehen.

3.4. Modeling: Modellierungsmethodologie

Die Modellierung ist ein zentraler Schritt im CRISP-DM-Prozess und bildet das Herzstück der Anwendung von KI-Methoden. Ziel dieses Abschnittes ist es, einen groben Einblick in die verschiedenen Modellierungstechniken zu geben.

Baseline-Modell

Bevor komplexere Modelle entwickelt werden, ist es sinnvoll, ein Baseline-Modell zu erstellen. Ein Baseline-Modell dient als einfache Referenz, gegen die die Leistung anderer Modelle gemessen werden kann. Es kann sich dabei um ein naives Modell handeln, das beispielsweise den Durchschnitt der bisherigen Werte als Vorhersage verwendet. Diese einfache Vorgehensweise ermöglicht es, schnell eine erste Einschätzung der Daten und der Vorhersagegenauigkeit zu bekommen. Das Baseline-Modell bietet eine solide Ausgangsbasis und hilft zu bestimmen, ob die Komplexität fortgeschrittener Modelle gerechtfertigt ist. Da der CRISP-DM-Prozess iterativ ist, kann später ein besser passendes Modell gewählt werden, das auf den Erkenntnissen der ersten Durchläufe aufbaut.

Im Rahmen des Projektes zur Vorhersage der Lastkurve wurde zunächst ein einfaches Baseline-Modell verwendet, das sogenannte „morgen wie heute“-Modell. Bei diesem Ansatz wird der Lastgang von heute als Vorhersage für morgen genutzt. Dieses Modell hat den Vorteil, dass es sehr einfach zu implementieren ist und eine erste Referenz für die Genauigkeit und Leistungsfähigkeit weiterer, komplexerer Modelle bietet.

Allerdings zeigte sich schnell eine Herausforderung durch diesen Ansatz. Der Lastgang von Freitag unterscheidet sich erheblich von dem eines Samstags, da am Wochenende weniger Menschen früh aufstehen und Energie verbrauchen. Darüber hinaus berücksichtigt das Modell keine Feiertage oder beson-

deren Ereignisse, die ebenfalls einen Einfluss auf den Wärmebedarf haben können. Trotz dieser Einschränkungen dient das „morgen wie heute“-Modell als nützliche Baseline, gegen die die Leistung fortschrittlicherer Modelle gemessen werden kann. Es bietet einen einfachen Vergleichsmaßstab, der hilft, die Verbesserung durch komplexere Vorhersagemodelle zu quantifizieren.

Abbildung 6 visualisiert die Baseline vom Freitag mit einem Lastgang vom Samstag.

Entscheidungsbäume

Entscheidungsbäume sind eine der einfachsten und gleichzeitig effektivsten Methoden des maschinellen Lernens. Sie funktionieren, indem sie die Daten in einer baumartigen Struktur in eine Abfolge von Entscheidungen unterteilen. Jeder Knoten im Baum stellt eine Entscheidung dar, die auf einem Merkmal der Daten basiert, und führt zu weiteren Verzweigungen, bis eine endgültige Klassifikation oder Vorhersage erreicht ist. Entscheidungsbäume sind leicht verständlich und interpretierbar, was sie besonders geeignet für kleine bis mittlere Datenmengen macht. Sie können sowohl für Klassifikations- als auch für Regressionsaufgaben verwendet werden. Ein FVU könnte Entscheidungsbäume verwenden, um basierend auf historischen Daten und Wettervorhersagen den zukünftigen Wärmebedarf zu prognostizieren.

k-Nearest Neighbor (k-NN)

Der k-Nearest-Neighbor-Algorithmus (k-NN) ist eine weitere einfache, aber leistungsstarke Technik. Er basiert auf der Idee, dass ähnliche Datenpunkte in der Nähe voneinander liegen. Um eine Vorhersage zu treffen, sucht k-NN die k nächstgelegenen Datenpunkte (Nachbarn) im Datensatz und verwendet




Abbildung 6: Lastgang über 24 Stunden. Gemessene Leistung und Baseline „morgen wie heute“. Quelle: Eigene Darstellung, dena, 2024

deren Werte, um die Vorhersage für einen neuen Datenpunkt zu bestimmen. k-NN ist einfach zu implementieren und zu verstehen, benötigt keine Annahmen über die Verteilung der Daten und ist flexibel einsetzbar. Ein FVU könnte k-NN verwenden, um Muster im Energiebedarf von Kundinnen und Kunden zu erkennen und zukünftige Nachfrageprofile zu erstellen.

Deep Learning

Deep Learning ist eine fortschrittlichere Methode des maschinellen Lernens, die insbesondere bei großen Datenmengen und komplexen Aufgaben leistungsfähig ist. Es basiert auf künstlichen neuronalen Netzen, die in der Lage sind, sehr tiefgehende und abstrakte Muster in den Daten zu erkennen. Eine umfangreichere Erklärung zu dieser Technik wird im Kapitel 1.4. Künstliche Intelligenz gegeben. Diese Methode zeichnet sich durch ihre hohe Genauigkeit bei der Verarbeitung großer und komplexer Datensätze aus und kann sehr komplexe Muster und Beziehungen in den Daten identifizieren. Ein FVU könnte Deep Learning nutzen, um präzise Vorhersagen über den Wärmebedarf zu erstellen, indem historische Betriebsdaten und umfangreiche Wetterdaten kombiniert werden.

Hyperparameter-Tuning

Ein weiterer wichtiger Aspekt der Modellierung ist das Hyperparameter-Tuning. Hyperparameter sind Einstellungen, die vor dem Training eines Modells festgelegt werden und die Architektur und das Verhalten des Modells bestimmen. Beispiele für Hyperparameter sind die Lernrate, die Anzahl der Schichten in einem neuronalen Netzwerk oder die Anzahl der Nachbarn in einem k-NN-Algorithmus. Das Anpassen dieser Hyperparameter ist entscheidend, da sie einen erheblichen Einfluss auf die Modellleistung haben. Durch systematisches Hyperparameter-Tuning können optimale Einstellungen gefunden werden, die das Modell sowohl leistungsfähiger als auch robuster machen. Dies kann durch Techniken wie Grid Search, Random Search oder spezialisierte Algorithmen wie Bayesian Optimization erreicht werden.

Für FVU, die diese Modellierungstechniken selbst umsetzen möchten, ist es wichtig, schrittweise vorzugehen und die Methoden an die spezifischen Bedürfnisse und vorhandenen Ressourcen anzupassen. Der Implementierungsprozess beginnt mit der Datenaufbereitung. Dabei wird sichergestellt, dass alle relevanten Daten in geeigneter Qualität und im geeigneten Format vorliegen. Die Datenaufbereitung ist ein entscheidender Schritt, da die Qualität der Daten einen direkten Einfluss auf die Genauigkeit und Zuverlässigkeit des Modells hat.

Nachdem die Daten aufbereitet wurden, erfolgt die Modellauswahl. Basierend auf den verfügbaren Daten und der spezifischen Aufgabenstellung wird das geeignete Modell ausgewählt. Beispielsweise könnte ein Entscheidungsbaum für kleinere Datensätze und einfachere Vorhersageaufgaben gewählt werden, während Deep Learning für große und komplexe Daten bevorzugt wird. Die Auswahl des richtigen Modells ist entscheidend, um die bestmöglichen Ergebnisse zu erzielen.

Der nächste Schritt ist das Modelltraining. Dabei wird das ausgewählte Modell mit den vorhandenen Daten trainiert, um es an die spezifischen Muster und Zusammenhänge anzupassen. Dies erfordert oft mehrere Iterationen, bei denen das Modell kontinuierlich angepasst und verbessert wird, um die bestmögliche Leistung zu erzielen. Wichtig hierbei ist, dass für das Training des Modells nicht sämtliche verfügbare Daten verwendet werden, sondern nur ein Anteil von 60 bis 80 Prozent. Die übrigen Anteile werden ausschließlich für die Leistungsevaluation verwendet.



Infobox: Achtung Overfitting

Overfitting tritt auf, wenn ein Modell die Trainingsdaten zu genau lernt, einschließlich der Rauschelemente und Ausreißer. Dies führt dazu, dass das Modell eine sehr hohe Genauigkeit bei den Trainingsdaten erreicht, aber bei den Testdaten, die das Modell noch nicht gesehen hat, schlecht abschneidet. Overfitting bedeutet, dass das Modell die spezifischen Muster der Trainingsdaten auswendig gelernt hat, anstatt die zugrunde liegenden generellen Muster zu erkennen. Um Overfitting zu vermeiden, können Techniken wie Cross-Validation, Regularisierung und ein Validierungssatz verwendet werden. Diese Methoden helfen, die Generalisierungsfähigkeit des Modells zu verbessern und seine Leistung in Bezug auf unbekannte Daten zu erhöhen.

Nach dem Training wird die Leistung des Modells evaluiert. Dabei wird überprüft, ob das Modell präzise und zuverlässig Vorhersagen treffen kann. Die Modellbewertung erfolgt anhand von verschiedenen Metriken wie der Genauigkeit, der Präzision, dem Recall oder dem F1-Score, je nach Art der Aufgabe. Eine sorgfältige Evaluation hilft, die Stärken und Schwächen des Modells zu identifizieren und sicherzustellen, dass es den Anforderungen entspricht.

Durch die Anwendung dieser Techniken können FVU ihre Betriebseffizienz steigern, Kosten senken und eine zuverlässigere Wärmeversorgung gewährleisten. Die Modellierung bietet somit eine mächtige Möglichkeit, die Potenziale der KI in der Praxis zu nutzen. Ein systematischer Ansatz zur Modellierung, der die spezifischen Bedürfnisse und Bedingungen berücksichtigt, kann entscheidend dazu beitragen, die Vorteile von KI-Technologien voll auszuschöpfen.

3.5. Evaluation: Evaluierung des Anwendungsfalls

Die Evaluierung eines KI-Projekts im Fernwärmenetz ist ein entscheidender Schritt, um den Erfolg der Implementierung zu bewerten. Dieser Schritt knüpft direkt an die in der Phase des **Business Understanding** definierten Ziele und Key Performance Indicators (KPIs) an. Zu Beginn des Projekts wurden klare geschäftsrelevante Kennzahlen formuliert, die nun als Grundlage für die Erfolgsmessung dienen. Diese KPIs bieten eine objektive Möglichkeit, die tatsächlichen Auswirkungen des Projekts auf das Unternehmen zu quantifizieren und den Mehrwert zu bewerten.

Rückbezug auf die Zielsetzung

Bereits in der ersten Phase des Projekts wurde erarbeitet, welche geschäftlichen Ziele durch den Einsatz von KI erreicht werden sollen. Typische Ziele in einem Fernwärmenetz könnten beispielsweise die **Vorhersage des Wärmebedarfs**, die **Optimierung der Kraftwerkswahl** oder die **Erkennung von Leckagen** sein. Diese Ziele wurden im Einklang mit den übergeordneten Geschäftsstrategien des Unternehmens festgelegt und sollten einen klaren Nutzen aufzeigen, der sowohl finanzieller als auch operationeller Natur ist.

In der Evaluierungsphase geht es nun darum, diese vorab festgelegten Ziele zu messen und zu überprüfen, inwiefern das KI-Projekt die gewünschten Ergebnisse geliefert hat. Eine zentrale Frage lautet dabei: **Wurden die gesetzten KPI erreicht?**

Beispiele für Geschäftskritische KPI

Die Bewertung des Projekterfolgs erfolgt anhand der vorab definierten KPI, die den Geschäftsnutzen widerspiegeln. Dazu könnten unter anderem folgende Kennzahlen gehören:

- **Energieeffizienz:** Ein Ziel des KI-Projekts könnte die Steigerung der Energieeffizienz sein. Durch präzisere Vorhersagen des Wärmebedarfs und eine optimierte Planung der Energieerzeugung kann es möglich sein, weniger Primärenergie einzukaufen. Eine Verbesserung der Energieeffizienz lässt sich durch den Vergleich der Verbrauchsdaten vor und nach der Implementierung des KI-Modells messen.
- **Betriebskostenreduktion:** Eine weitere wichtige Kennzahl könnte die Reduzierung der Betriebskosten sein, beispielsweise durch den optimierten Einsatz von Kraftwerken. Durch die bessere Planung und Steuerung der Energieproduktion können kosteneffizientere Technologien wie Wärmepumpen verstärkt genutzt und gleichzeitig teurere Ressourcen eingespart werden.
- **Arbeitsentlastung:** Ein KI-Projekt kann ebenfalls zu einer Reduzierung der Arbeitsbelastung führen. Beispielsweise könnte durch präzisere Vorhersagen und automatisierte Prozesse die Anzahl der Anrufe an der Kundenhotline

sinken, da Störungen oder unvorhergesehene Engpässe im Netz reduziert werden. Dies entlastet die Mitarbeiterinnen und Mitarbeitern und steigert die betriebliche Effizienz.

Methoden der Evaluierung

Um die oben genannten KPI zu bewerten, sollten geeignete Methoden und Werkzeuge zur Anwendung kommen. Dies könnte eine Kombination aus quantitativen und qualitativen Methoden sein, wie:

- **Vergleich mit der Baseline:** Eine einfache, aber effektive Methode besteht darin, die Leistungsdaten des KI-Modells mit denen des Baseline-Modells zu vergleichen. Wurden durch das KI-Modell signifikante Verbesserungen in den KPI erzielt?
- **Datenanalyse:** Eine umfassende Analyse der Betriebsdaten vor und nach der Einführung des KI-Systems gibt Aufschluss über die Verbesserungen. Dies könnte die Analyse der Energieverbrauchsdaten oder der Anzahl der Kundenanfragen umfassen.
- **Feedback der Nutzerinnen und Nutzer:** Neben der Analyse der Betriebsdaten kann das Feedback der betroffenen Mitarbeiterinnen und Mitarbeitern, wie beispielsweise der Netzmeister und Leitwartenmitarbeitenden, wertvolle Informationen darüber liefern, wie sich das KI-System in der Praxis bewährt hat. Haben die Mitarbeitenden das Gefühl, dass ihre Arbeit durch das KI-Modell erleichtert wurde? Werden die Systeme in der täglichen Arbeit aktiv genutzt?

Iterative Verbesserung

Das CRISP-DM-Modell sieht einen iterativen Ansatz vor, bei dem die Modellierung und Implementierung kontinuierlich angepasst werden. Sollte die Evaluierung zeigen, dass die erwarteten KPI nicht vollständig erreicht wurden, kann es sinnvoll sein, das Modell zu überarbeiten und zu optimieren. In der Evaluierungsphase wird daher auch entschieden, ob das bestehende Modell weiter genutzt oder durch ein verbessertes Modell ersetzt werden soll.

Fazit

Die Evaluierung des KI-Projekts ist von zentraler Bedeutung, um sicherzustellen, dass die in der Phase des **Business Understanding** definierten Ziele erreicht wurden. Es gilt, die Leistung des Modells im Betrieb zu messen und den tatsächlichen Geschäftsnutzen zu bewerten. Eine erfolgreiche Evaluierung zeigt auf, wie sich das KI-System auf die Betriebseffizienz, die Kosten und die Arbeitsprozesse im Fernwärmenetz ausgewirkt hat, und bildet die Grundlage für zukünftige Optimierungen und Erweiterungen.

Im Rahmen des Projektes „KI in Fernwärme“ wurden Multilayer Perceptrons (MLP) und Long Short-Term Memory (LSTM)-Netzwerke verwendet, die den Lastgang für morgen vorhersagen. Diese Technologien fallen in den Bereich des Deep Learning, welches in Kapitel 1.4.6. eingeführt wurde.

Multilayer Perceptrons (MLP)

Ein Multilayer Perceptron ist eine Art von künstlichem neuronalem Netz, das aus mehreren Schichten von Neuronen besteht: einer Eingabeschicht, einer oder mehreren versteckten Schichten und einer Ausgabeschicht. Jede Schicht besteht aus Neuronen, die mit den Neuronen der vorherigen und der nächsten Schicht verbunden sind. Die Eingabeschicht nimmt die Eingangsdaten auf, die versteckten Schichten verarbeiten diese Daten durch gewichtete Verbindungen und Aktivierungsfunktionen und die Ausgabeschicht gibt das Ergebnis aus. MLP sind in der Lage, komplexe Muster in den Daten zu erkennen, und können für verschiedene Arten von Vorhersage- und Klassifikationsaufgaben verwendet werden.

Long Short-Term Memory (LSTM)

LSTM ist eine spezielle Art von rekurrentem neuronalem Netz (RNN), das entwickelt wurde, um Sequenzdaten zu verarbeiten und langfristige Abhängigkeiten zu lernen. Im Gegensatz zu herkömmlichen RNNs können LSTM-Netzwerke Informationen über lange Zeiträume hinweg speichern und nutzen. Dies wird durch spezielle Einheiten, sogenannte „Zellen“, ermöglicht, die durch drei Arten von Toren gesteuert werden: Eingangstore, Ausgangstore und Vergessensgatter. Diese Tore regulieren den Informationsfluss innerhalb der Zellen und ermöglichen es dem LSTM, relevante Informationen über längere Sequenzen hinweg beizubehalten und irrelevante Informationen zu vergessen.

Eingabedaten und Vorhersage

Für die Vorhersage der Lastkurve wurden verschiedene Umweltdaten als Eingaben verwendet, darunter Außentemperatur, Windgeschwindigkeit, Sonnenstunden und Wochentag. Diese Daten wurden zu einem Eingabevektor zusammengeführt, der als Grundlage für die Vorhersage des Lastprofils diente. Die Modelle wurden darauf trainiert, basierend auf diesen Eingaben den Wärmebedarf für die nächsten 24 oder 48 Stunden vorherzusagen.

Durch die Integration dieser vielfältigen Datenquellen konnten die neuronalen Netze komplexe Muster und Abhängigkeiten im Wärmeverbrauch erkennen und präzise Vorhersagen treffen. Die Nutzung von LSTM-Netzwerken war besonders vorteilhaft, da sie in der Lage sind, zeitliche Abhängigkeiten und Trends in den Daten zu berücksichtigen, was zu genaueren und verlässlicheren Vorhersagen führte.

Die Kombination von Multilayer Perceptrons und LSTM-Netzwerken ermöglichte es, die Stärken beider Ansätze zu nutzen und eine robuste Lösung zur Vorhersage des Wärmebedarfs zu entwickeln.

In Abbildung 7 ist erkennbar, dass die Vorhersagen des neuronalen Netzes (LSTM+MLP) geringere Abweichungen gegenüber den Messwerten liefert als der Baseline-Ansatz „morgen wie heute“.




Abbildung 7: Lastgang Fernwärmenetz über 24 h. Darstellung und Vergleich von Vorhersagemodellen (LSTM+MLP und Baseline) und Messwerten. Quelle: Eigene Darstellung, dena, 2024

Fehlerfunktion und spezialisierte Anpassungen

Eine Fehlerfunktion (Loss Function) ist eine zentrale Komponente beim Training neuronaler Netze. Sie misst den Unterschied zwischen den vorhergesagten Werten des Modells und den tatsächlichen Werten aus den Trainingsdaten. Das Ziel des Trainingsprozesses ist es, diese Fehlerfunktion zu minimieren, sodass die Vorhersagen des Modells möglichst genau sind. Häufig verwendete Fehlerfunktionen sind der Mean Squared Error (MSE) für Regressionsaufgaben und die Cross-Entropy für Klassifikationsaufgaben.

Im Kontext des Fernwärmeprojekts wurde eine spezialisierte Fehlerfunktion verwendet, die den spezifischen Anforderungen eines FVU gerecht wird. Es ist erheblich schwerwiegender, wenn zu wenig Wärme bereitgestellt wird und die Menschen im Winter frieren, als wenn zu viel Wärme bereitgestellt wird. Daher wurde eine Fehlerfunktion entwickelt, die eine zu niedrige Vorhersage stärker bestraft als eine zu hohe Vorhersage.

Diese spezialisierte Fehlerfunktion sorgt dafür, dass das Modell während des Trainings lernt, eine konservative Schätzung abzugeben, um sicherzustellen, dass stets ausreichend Wärme zur Verfügung steht. Indem Fehlvorhersagen asymmetrisch gewichtet werden, wird die Zuverlässigkeit des Systems in kritischen Situationen verbessert. Diese Anpassung der Fehlerfunktion ist ein Beispiel dafür, wie KI-Modelle an die spezifischen Bedürfnisse und Risiken einer Anwendung angepasst werden können, um die bestmöglichen Ergebnisse zu erzielen.

Durch die Anwendung dieser Techniken und Anpassungen konnten FVU eine präzise und zuverlässige Lösung zur Vorhersage des Wärmebedarfs entwickeln, die sowohl die betrieblichen Anforderungen als auch die Bedürfnisse der Endverbraucherinnen und Endverbraucher berücksichtigt.

Method	MAE	RMSE
Baseline	455 kW	684 kW
KNN	371 kW	549 kW
MLP	371 kW	550 kW
LSTM	180 kW	256 kW

Tabelle 2: Vergleich der Genauigkeit verschiedener Methoden. Quelle: Eigene Darstellung, dena, 2024

Die Auswertung der Experimente zeigt, dass das LSTM-Modell die besten Vorhersagen für die Lastkurve liefert, gefolgt von KNN und MLP. Das Baseline-Modell, obwohl einfach und schnell zu implementieren, konnte in Bezug auf Genauigkeit und Zuverlässigkeit nicht mit den fortgeschritteneren Methoden mithalten. Diese Ergebnisse verdeutlichen den Mehrwert, den komplexe neuronale Netzwerke wie LSTM bieten, insbesondere wenn es darum geht, genaue und zuverlässige Vorhersagen im Fernwärmesektor zu treffen.

Die experimentellen Ergebnisse bestätigen, dass die sorgfältige Auswahl und Anpassung von Modellen entscheidend für den Erfolg eines KI-Projekts ist. Die Berücksichtigung von zeitlichen Abhängigkeiten und die Verwendung spezialisierter Fehlerfunktionen können die Genauigkeit und Zuverlässigkeit der Vorhersagen erheblich verbessern und somit einen wichtigen Beitrag zur Optimierung der Betriebsführung im Fernwärmenetz leisten.

3.6. Deployment: Integration der Systeme

Die Integration der entwickelten KI-Modelle in die bestehenden Systeme eines FVU ist ein entscheidender Schritt im CRISP-DM-Prozess, auch bekannt als Deployment. Dieser Schritt stellt sicher, dass die erstellten Modelle tatsächlich genutzt werden und ihren vollen Nutzen entfalten können. Bei der Integration müssen verschiedene technische und organisatorische Aspekte berücksichtigt werden.

Zusammenarbeit mit der IT-Abteilung

Eine enge Zusammenarbeit mit der IT-Abteilung ist unerlässlich, um die Integration erfolgreich umzusetzen. Es ist wichtig, frühzeitig abzuklären, welche Schnittstellen vorhanden sind und wie diese genutzt werden können. Dabei sollten die Anforderungen des Modells und die technischen Gegebenheiten der bestehenden IT-Infrastruktur aufeinander abgestimmt werden. Dies hilft, potenzielle Probleme frühzeitig zu erkennen und geeignete Lösungen zu finden.

Betrieb des Modells hinter einer geeigneten Schnittstelle

Das Modell sollte hinter einer geeigneten Schnittstelle betrieben werden, um die Integration in die bestehenden Systeme zu erleichtern. Eine häufig verwendete Methode ist die Bereitstellung des Modells über eine REST-API. Eine REST-API (Representational State Transfer – Application Programming Interface) ist eine Schnittstelle, die es ermöglicht, Daten über das HTTP-Protokoll zu senden und zu empfangen. Sie ist einfach zu implementieren und zu nutzen, da sie auf standardisierten Webtechnologien basiert. REST-APIs sind flexibel und können in verschiedenen Programmiersprachen implementiert werden, was sie zu einer idealen Lösung für die Integration von KI-Modellen macht.

Continuous Integration and Continuous Deployment (CI/CD)

Um sicherzustellen, dass das Modell kontinuierlich verbessert und aktualisiert werden kann, sollten Methoden wie Continuous Integration and Continuous Deployment (CI/CD) verwendet werden. Continuous Integration (CI) bezieht sich auf die regelmäßige Zusammenführung von Codeänderungen in ein gemeinsames Repository (zentraler digitaler Speicher), gefolgt von automatisierten Tests, um sicherzustellen, dass keine neuen Fehler eingeführt werden. Continuous Deployment (CD) baut auf CI auf und automatisiert die Bereitstellung des getesteten Codes in der Produktionsumgebung. Diese Methoden ermöglichen eine schnelle und zuverlässige Aktualisierung des Modells und stellen sicher, dass Verbesserungen und Anpassungen zeitnah in die Produktion überführt werden können.

Sicherstellung der Skalierbarkeit

Ein weiterer wichtiger Aspekt ist die Sicherstellung der Skalierbarkeit der Lösung. Das bedeutet, dass die Systemarchitektur so gestaltet sein muss, dass sie bei steigenden Anforderungen und wachsender Datenmenge problemlos erweitert werden kann. Dies kann durch den Einsatz von Cloud-Technologien und skalierbaren Architekturen erreicht werden, die eine flexible Anpassung der Ressourcen ermöglichen.

Einbeziehung der Nutzerinnen und Nutzern

Ein wesentlicher Aspekt der erfolgreichen Integration von KI-Systemen ist die Einbeziehung der Endnutzerinnen und Endnutzer in den gesamten Prozess. Dabei sollte insbesondere auf die Benutzererfahrung (User Experience, UX) geachtet werden. UX bezieht sich auf die Gesamtheit der Erfahrungen und Interaktionen, die Benutzerinnen und Benutzer mit einem System oder einer Anwendung haben. Ein KI-System, das zwar technisch einwandfrei funktioniert, aber schwer zu bedienen ist, wird von den Nutzerinnen und Nutzern möglicherweise nicht akzeptiert oder nur widerwillig verwendet.

Es ist daher wichtig, von Anfang an die Bedürfnisse und Anforderungen der Nutzerinnen und Nutzern zu berücksichtigen. Dies kann durch regelmäßige Feedback-Schleifen, Usability-Tests und Schulungen erreicht werden. Eine gute UX stellt sicher, dass die Benutzerinnen und Benutzer das System effizient und effektiv nutzen können und somit die Akzeptanz und der Nutzen des Systems maximiert werden.

3.7. Laufender Betrieb: Überwachung, Wartung, Aktualisierung

Die kontinuierliche Überwachung, Wartung und Aktualisierung eines KI-Systems sind entscheidende Prozesse, um dessen langfristige Effizienz und Relevanz sicherzustellen. Diese Schritte gewährleisten, dass das System nicht nur optimal funktioniert, sondern auch auf Veränderungen in den Daten oder den Betriebsbedingungen reagieren kann.

Überwachung

Die Überwachung des KI-Systems umfasst die kontinuierliche Beobachtung der Modellleistung und des Systemverhaltens. Dies beinhaltet die Überprüfung von Schlüsselkennzahlen (KPI), die das System überwachen soll, wie zum Beispiel Vorhersagegenauigkeit, Reaktionszeit und Systemverfügbarkeit. Durch die Implementierung eines robusten Monitoring-Frameworks können Anomalien oder Leistungsabfälle frühzeitig erkannt und behoben werden. Dazu gehört auch die Einrichtung von Alarmen und Benachrichtigungen, die bei bestimmten Schwellenwertüberschreitungen ausgelöst werden.

Eine effektive Überwachung stellt sicher, dass das KI-System zuverlässig arbeitet und seine Aufgaben wie erwartet erfüllt. Dies kann durch regelmäßige Reports und Dashboards unterstützt werden, die den aktuellen Status und die Leistung des Systems visualisieren. Darüber hinaus sollte das Monitoring-System in der Lage sein, historische Daten zu analysieren, um Trends zu erkennen und potenzielle Probleme vorherzusagen.

Wartung

Die Wartung eines KI-Systems ist ein fortlaufender Prozess, der darauf abzielt, das System in einem optimalen Betriebszustand zu halten. Dazu gehören regelmäßige Überprüfungen und Kalibrierungen des Modells, um sicherzustellen, dass es weiterhin akkurat arbeitet. Da sich die zugrunde liegenden Daten ändern können, ist es wichtig, das Modell regelmäßig zu aktualisieren und zu validieren.

Ein weiterer Aspekt der Wartung ist das Management der Systemressourcen, um sicherzustellen, dass das KI-System effizient und ohne Unterbrechungen läuft. Dies kann die Überwachung der Hardwareleistung, das Management der Datenbankressourcen und die Sicherstellung der Netzwerksicherheit umfassen. Regelmäßige Wartungsarbeiten tragen dazu bei, dass das System stabil und sicher bleibt.

Aktualisierung

Aktualisierungen sind notwendig, um das KI-System an neue Daten, veränderte Betriebsbedingungen oder neue technologische Entwicklungen anzupassen. Dies kann die Einführung neuer Algorithmen, die Verbesserung der Datenverarbeitungsprozesse oder die Integration neuer Datenquellen umfassen. Eine strukturierte Vorgehensweise zur Durchführung von

Updates stellt sicher, dass Änderungen sorgfältig geplant und implementiert werden, um minimale Beeinträchtigungen des laufenden Betriebs zu gewährleisten.

Ein wichtiger Bestandteil der Aktualisierung ist die Modellpflege. Da sich die Datenbasis und die Betriebsbedingungen ändern können, ist es notwendig, das Modell regelmäßig neu zu trainieren und zu validieren. Dies kann durch automatisierte Retrainingprozesse unterstützt werden, die sicherstellen, dass das Modell stets auf dem neuesten Stand ist.


Zusammenfassung

Die Etablierung eines Prozesses für die Überwachung, Wartung und Aktualisierung des KI-Systems ist entscheidend für dessen langfristigen Erfolg. Durch kontinuierliches Monitoring können Leistungsprobleme frühzeitig erkannt und behoben werden. Regelmäßige Wartungsarbeiten halten das System in einem optimalen Betriebszustand. Durch gezielte Aktualisierungen bleibt das System relevant und effizient. Diese Maßnahmen tragen dazu bei, die Investition in das KI-System zu schützen und dessen Nutzen für das Unternehmen zu maximieren.

4.

Herausforderungen bei der Umsetzung von KI-Projekten

Im Laufe des Projekts wurden zahlreiche wertvolle Erfahrungen gesammelt. Dieses Kapitel fasst die wichtigsten Erkenntnisse zusammen, die im Verlauf der Projektentwicklung und -umsetzung gewonnen wurden. Um genau zu verstehen, mit welchen Herausforderungen der Projektpartner Stadtwerke Norderstedt im Projekt „KI in Fernwärme“ konfrontiert war, führte die dena im April 2024 ein Experteninterview mit Tim Storbeck durch. In den identifizierten Herausforderungen sowie im Erfahrungsbericht der Stadtwerke wird deutlich, welchen bedeutenden Einfluss die Digitalisierung auf die Bewältigung technischer Herausforderungen haben kann. Es wird ersichtlich, dass digitale Technologien und Innovationen in der Energiebranche eine zentrale Rolle für eine effizientere Zukunft spielen werden.



4.1. Herausforderungen im Projekt „KI in Fernwärme“

Das folgende Kapitel bietet eine Übersicht über die Herausforderungen sowie unerwarteten Hürden und auch mögliche Lösungsansätze. Durch die Analyse und Dokumentation dieser Erfahrungen wird sichergestellt, dass bewährte Praktiken weitergegeben und potenzielle Fallstricke vermieden werden. Die Herausforderungen wurden den Einflussphasen der beteiligten Akteure zugeordnet.

Herausforderungen in den Einflussphasen von Fernwärmeversorgungsunternehmen

Schlechte Verfügbarkeit historischer Daten

Historische Daten sind häufig nur in hoch aggregierter Form vorhanden, um das Datenvolumen in der Datenbank zu verringern, was jedoch für KI-Trainingszwecke ungeeignet ist. Um dieses Problem zu lösen und um die detaillierten historischen Daten zu erhalten, müsste die Datenaggregation frühzeitig deaktiviert werden. Gegebenenfalls können hochaufgelöste Daten auch in eine gesonderte Datenbank weitergeleitet werden, welche ausschließlich zur Archivierung verwendet wird.

Schlechte Punkte im Netz unbekannt

Betreiber wissen oft nicht genau, wo sich die Schlechtepunkte im Netz befinden. Durch die Analyse von Live-Daten können Versorgungstemperaturen identifiziert und an diesen Stellen zusätzliche Messtechnik (für Temperatur und gegebenenfalls Druck(differenz)) installiert werden, um die Datenauflösung zu erhöhen. Dies würde eine Betriebsführung auf Basis von Feld-Messdaten und nicht ausschließlich auf Basis von Erfahrungswerten ermöglichen.

Geringe Informationslage zu Anomalien in den Zeitreihen

Es ist oft schwer zu unterscheiden, ob es sich bei Anomalien in den Zeitreihen um Ausfälle oder geplante Wartungsarbeiten handelt. Die Digitalisierung des Wartungslogbuchs der Wärmeerzeuger kann hier Abhilfe schaffen.

Fehlende Informationen zu Direktvermarktern von Strom und den BHKWs

Die Aktivitäten von Direktvermarktern werden oft nicht in den Daten aufgezeichnet. Es ist wichtig, Schaltsignale dieser Vermarkter zu erfassen, um die Daten korrekt interpretieren zu können.

Aufbau und Inbetriebnahme des Data Warehouse sehr aufwändig

Die Einrichtung eines Data Warehouse erfordert die Anpassung vieler verschiedener Schnittstellen und ist oft mit erheblichen Aufwänden verbunden. Ein detaillierter Plan für den Aufbau und die Integration in die bestehende Systeminfrastruktur ist notwendig. Außerdem ist die Zusammenarbeit mit externen Dienstleistern und eine klare Kommunikation der sich ändernden Anforderungen entscheidend.

Zu viele Speicherorte von Informationen zum Fernwärmenetz

Eine dezentrale Speicherung von Daten über viele Jahre hinweg führt zu fehlender Übersicht und lückenhaften Daten. Die Einführung einer standardisierten Datenstruktur auf einer zentralen Plattform kann hier Abhilfe schaffen.

Messdatenintervalle der HASTs sehr lückenhaft

Die Datenübertragung über LoRa-Netzwerke zeigte sich als lückenhaft, da der Empfang oft unzureichend war. Um die Datenlücken zu schließen, wurden kurzfristig zusätzliche LoRa-Basisstationen installiert. Eine datenwissenschaftliche Analyse ist notwendig, um diese Lücken zu identifizieren, betroffene Sendestationen zu identifizieren und die Position der LoRa-Stationen zu optimieren.

Geänderte Randbedingungen im Fernwärmenetz

Veränderungen im Fernwärmenetz, wie die Integration neuer Wärmeerzeuger oder Umbauten, verändern die Bedingungen, unter denen die KI trainiert wurde. Diese Änderungen müssen frühzeitig erfasst und in das KI-Training einbezogen werden.

Fehlende Regelbeschreibung für Heizwerke

Oft fehlen dokumentierte Regelbeschreibungen für Energiezentralen, da Anpassungen mündlich während der Reglerprogrammierung erfolgen. Eine Lösung besteht darin, die grundlegenden Regelgrößen in das Hydraulikschema der Anlagen zu integrieren oder Algorithmen zur Erkennung von Regelentscheidungen zu entwickeln.

Ökonomischer Wert von Messdaten unbekannt

Der zusätzliche ökonomische Nutzen von mehr Messtechnik ist oft unklar. Eine Untersuchung des ökonomischen Mehrwerts zusätzlicher Messtechnik für den Netzbetreiber kann hier wertvolle Erkenntnisse liefern.

Herausforderungen an der Schnittstelle der Einflussphären von FVU und KI-Lösungsanbietern

Extraktion von Daten aus Prozessleittechnik (PLT) aufwändig

Ein zentrales Problem bei der Implementierung von KI in Fernwärmenetzen ist, Daten aus der Prozessleittechnik zu extrahieren. Die PLT von Fernwärmenetzen zählt zur kritischen Infrastruktur und ist daher besonders gesichert. Oftmals wissen die Betreiber nicht, wie diese Daten erhoben und verarbeitet werden können, da die PLT beispielsweise von einem externen Dienstleister eingerichtet und betrieben wird. Es ist essenziell, dass die PLT-Daten aufgezeichnet und über maschinenlesbare Schnittstellen verfügbar gemacht werden. Im vorliegenden Projekt konnte die bestehende PLT, welche alle Daten zentral gespeichert hatte, durch eine Software-Erweiterung täglich CSV-Dateien via E-Mail versenden.

Abriss der Datenexportes via E-Mail aus der Prozessleittechnik

Störungen in einem Teilsystem der Prozessleittechnik führen dazu, dass E-Mail-Exporte der Daten abbrechen. Es ist wichtig, ein System zu betreiben, das diese Störungen meldet und behebt, um eine kontinuierliche Datenübertragung sicherzustellen. Die dadurch entstandenen Lücken in den Zeitreihen mussten durch manuelle Eingriffe (Datenextraktion und Export in die Zeitreihendatenbank für das KI-Training) geschlossen werden.

Abbruch der IoT-Plattform-Datenauslesung

Der automatische Datenabruf der HAST-Betriebsdaten auf der IoT-Datenplattform eines externen Dienstleisters der Stadtwerke Norderstedt läuft häufig in Verbindungslimits und bricht ohne Rückmeldung ab. Dies erfordert zeitintensive Neuverbindungsversuche und die Reduzierung der Anzahl gleichzeitiger Verbindungen. Die dadurch entstehenden Lücken müssen ebenfalls manuell durch einen Datenexport von der IoT-Datenplattform für die betroffenen Zeiträume geschlossen werden. Eine Abhilfe hierfür ist eine Anpassung der Systemarchitektur zur Datenauslesung. Da die HAST-Daten via LoRa nicht hochaufgelöst erhoben und auf der IoT-Plattform bereitgestellt werden, kann

der Datenabruf seriell und auch mit höherem Ausleseintervall durchgeführt werden.

Aufwändiger Bezug von Live-Daten zur Vorhersage des Erzeugerfahrplans des nächsten Tags

Das zum Schutz vor Hackerangriffen geschlossene System der PLT erschwert das Abrufen von Live-Betriebsdaten der Wärmeerzeuger. Eine Lösung besteht in der Nutzung von gesicherten VPN-Verbindungen. Eine verzögerte Bereitstellung der Prognosedaten (Strompreis- sowie Wetterprognosen) verzögert die Vorhersage des Erzeugerfahrplans ebenfalls. Während es für Wetterprognosen diverse Anbieter gibt, ist der Live-Bezug von Strompreisprognosen eine Herausforderung. Historische Strompreisdaten können hingegen von der SMARD-Plattform der Bundesnetzagentur (<https://www.smard.de/>) bezogen werden und für das Training eines eigenen Strompreis-Prognosemodells verwendet werden. Um die Abweichungen in der Preisprognose möglichst gering zu halten, empfiehlt es sich jedoch, die gleichen Prognosedaten der Stadtwerke zu verwenden.

Technische Schwierigkeiten beim Einspielen von Prognosen in die Leittechnik

Die manuelle Eintragung der prognostizierten Leistungswerte je Erzeuger bleibt oft die einzige Möglichkeit. Ursache hierfür ist, dass die Heizwerke im Wesentlichen durch ein Lastmanagement automatisiert gesteuert werden, welches auf Messungen des Netzdifferenzdrucks am Heizwerk, der Außentemperatur, sowie weiterer Faktoren (Strompreis, Pufferfüllstände etc.) basiert. Automatisierte Schnittstellen könnten hier zukünftig Abhilfe schaffen. Hier gilt es, die Anforderungen an kritische Infrastruktur zu berücksichtigen.

Herausforderungen in den Einflussphären von KI-Lösungsanbietern

Beschaffung von Strompreisdaten schwierig

Die hohen Kosten für Strompreisdaten (historische, hochaufgelöste und auch Echtzeitdaten bzw. Prognosen) stellen eine Herausforderung dar, da diese für das Training und Validierung des Prognosemodells und die Erstellung des Erzeugerfahrplans von hoher Bedeutung sind. Die Daten sind für die Vorhersage des Erzeugereinsatzplans erforderlich, da der Strompreis unmittelbaren Einfluss auf die Betriebszeiten, Erlöse sowie Betriebskosten der Erzeuger hat. Es empfiehlt sich, alternative Bezugsquellen wie Stadtwerke oder die dena zu prüfen.

Kombination historischer Daten mit Live-Daten aufwendig

Die Zusammenführung historischer Daten, die oft als CSV-Dateien vorliegen, mit aktuellen Live-Daten ist mit hohem Aufwand verbunden. Dies ist notwendig, um einen umfassenden Datensatz für das Training der KI-Modelle zu erstellen. Dieses Problem tritt in der Regel nur einmal auf, wenn die historischen Daten in das gleiche Format wie die Live-Daten gebracht und gespeichert werden.

4.2. Perspektivwechsel: Herausforderungen für die Stadtwerke Norderstedt

Bei der Entscheidung, KI-Lösungen in Unternehmensprozesse bei FVU zu integrieren, sind diverse Herausforderungen zu bewältigen. Neben der Schaffung technischer Voraussetzungen, der Etablierung einer vertrauten Arbeitsweise mit Künstlicher Intelligenz sowie der Befähigung der Mitarbeiterinnen und Mitarbeiter müssen auch energiepolitische und rechtliche Aspekte berücksichtigt werden.

Tim Storbeck ist Fachgebietsleiter bei den Stadtwerken Norderstedt für die Bereiche Gas, Wasser und Wärme. Im Rahmen des Projekts wurde am Fernwärmenetz der Stadtwerke Norderstedt eine KI-basierte Wärmelastprognose erstellt, welche in Kombination mit einer intelligenten Erzeugereinsatzplanung einen energetisch und wirtschaftlich optimierten Erzeugerfahrplan für die nächsten 24 Stunden ausgibt. Dabei werden Erzeugerstrukturen, Kosten und Erlöse sowie Speicherkapazitäten berücksichtigt. Im Folgenden gibt Tim Storbeck Einblicke in die technologischen, personellen, operativen und energiepolitischen Herausforderungen der Stadtwerke Norderstedt:



Tim Storbeck
Fachgebietsleiter bei den Stadtwerken Norderstedt

Technologische Herausforderungen



Die frühzeitige Etablierung einer Datenstrategie und -kultur stellt für FVU einen wichtigen ersten Schritt dar. Durch eine präzise Definition der einzelnen Elemente einer Datenstrategie, wie beispielsweise der Rollen, Verantwortungen oder der Datenarchitektur, können Fehler in der Umsetzung vermieden werden. Bei der Umsetzung kann eine sukzessive Vorgehensweise helfen, Herausforderungen frühzeitig zu erkennen und diesen entgegenzusteuern.

dena: Welche Herausforderungen gibt es bei der Datenverfügbarkeit, insbesondere in Bezug auf historische Daten, Datenschnittstellen und -formate sowie Messtechnik?

Storbeck: Viele Datenformate sind historisch gewachsen, oft durch Vorgaben aus verschiedenen Betriebsabteilungen geprägt. In der Netzleitwarte verfügen wir über umfangreiche historische Daten. Theoretisch könnten wir sekundliche Daten ausgeben, doch dies würde die Datenmenge auf ein unüberschaubares Niveau anwachsen lassen. Daher suchen wir immer nach einem Kompromiss zwischen einem guten Datenstand und der Vermeidung übermäßiger Datenmengen. Unsere Datenformate sind sehr unterschiedlich und es gibt keine einheitliche Konsistenz. Einige Datenpunkte werden minütlich erfasst, andere stündlich. Hier müssen wir für mehr Konsistenz in der Datenerhebung sorgen, zum Beispiel durch die Festlegung fester Intervalle für bestimmte Datentypen. Allerdings wäre eine pauschale Vereinheitlichung für alle Daten unsinnig, da dies zu unnötig hohen Datenbeständen führen würde. Unsere Empfeh-

lung ist, klar zu definieren, welche Daten tatsächlich relevant sind und in welchem Format und welcher Auflösung sie benötigt werden. Dies erfordert eine Einigung auf einheitliche Formate.

dena: Woher kamen die Anforderungen für die Datenauflösung? Hattet ihr schon Informationen darüber, welche Daten in welchem Format für solche KI-Anwendungsfälle benötigt werden?

Storbeck: Der ursprüngliche Fokus lag nicht direkt auf der Anwendung von KI. Diese Anforderungen kamen erst in Zusammenarbeit mit der RAUSCH Technology GmbH hinzu. Unsere Erfahrung zeigt, dass wir uns an den Datenaufösungen aus der Energiebeschaffung orientieren können. Diese haben sich als ausreichend genau erwiesen, was auch durch dieses Projekt bestätigt wurde.

dena: Stichwort Datenimport in die Leitwarte. Wie ist die Integration in die bestehenden Systeme verlaufen?

Storbeck: Nicht nur der Datenimport, sondern auch der Datenexport ist von großer Bedeutung, um eine vollständige Integration unserer Systeme zu gewährleisten. Die zwei wichtigsten Datenquellen sind hierbei die Leitwarte mit all ihren Erzeugungsanlagen und die Zählerdaten. Die Leitwarte ist ein abgeschlossenes System, das vom normalen Netzwerk getrennt ist, um eine höhere Sicherheitsstufe zu gewährleisten. Das macht den Datenaustausch besonders anspruchsvoll.

In diesem Projekt haben wir uns für einen täglichen Datenexport via E-Mail und einer CSV-Datei entschieden. Diese Lösung war jedoch nicht besonders komfortabel und erforderte einen erheblichen Aufwand, da keine dauerhafte Schnittstelle existiert. Zudem sind während des Projekts zeitweise Probleme aufgetreten, bei denen der Export nicht funktionierte.

dena: Was könnte man besser machen? Sollte man von Import und Export absehen, da die Netzleitwarte ein geschützter Raum bleiben soll? Oder gibt es technische Möglichkeiten?

Storbeck: Es gibt definitiv technische Möglichkeiten, die wir nutzen könnten. Eine davon ist die Einrichtung eines Data Warehouse, welches wir im Zuge des Projektes ebenfalls aufbauen wollten. Allerdings gab es auch hier Schwierigkeiten bei der Umsetzung. Diese haben uns verdeutlicht, dass ein Data Warehouse³ nicht einfach durch das Zusammenführen von Daten entsteht. Ein detaillierter Plan für den Aufbau und die Integration ist notwendig. Es muss genau festgelegt werden, wie die Daten hineinfließen und wie sie wieder entnommen werden können. Unser Ziel ist es, ein Data Warehouse zu etablieren und offene Schnittstellen zur Netzleittechnik und den Zählerdaten zu schaffen.

dena: Wieso musset ihr neu anfangen? Wo waren die Schwierigkeiten? Lag es an der bestehenden Struktur?

Storbeck: Das Ziel war der Aufbau im Energiemanagementsystem. Bisher wird hier im Bereich sehr viel mit Excel gearbeitet, was das Potenzial für eine Optimierung besonders groß macht. Das Projekt wuchs jedoch immer weiter und gemeinsam mit der IT entschieden wir, es zeitweise zu stoppen. Der geleistete Arbeitsaufwand stand nicht mehr im Verhältnis zu den geplanten Ergebnissen. Wir wollten das Projekt aber nicht abbrechen, sondern nur unterbrechen, um es danach strukturierter anzugehen. Deshalb organisierten wir einen Workshop mit allen Beteiligten, um offene Fragen zu klären. Konkret ging es uns darum, vorab mehr Fokus auf die zentralen Fragen zu legen: Wie und welche Daten sollen gesammelt werden? Wer ist Eigentümer der Daten und wer trägt Verantwortung? Woher kommen die Daten? Wer muss bei dem Projekt mitarbeiten? Danach sollte sukzessive mit der Datenerhebung begonnen werden. Uns wurde an dieser Stelle klar, dass die Nutzung aller Daten des Stadtwerks die Datenmenge zu groß machen würde. Es erscheint uns sinnvoller, mit einer kleineren Datenmenge zu beginnen und dafür zu sorgen, dass diese erweiterbar ist.

dena: Wofür würde man so ein Data Warehouse benutzen?

Storbeck: Das Interesse an der Sammlung und Analyse von Daten ist groß. Wenn wir die Daten einmal haben, werden sie in vielerlei Hinsicht nützlich sein. Zum Beispiel, wenn ein Betriebsleiter ein Dashboard mit den Kennzahlen seiner Erzeugungsanlagen sehen

könnte. Das Data Warehouse würde Betriebsoptimierungen deutlich erleichtern und könnte auch für weitere Forschungsprojekte genutzt werden.

dena: Für die Übertragung der Daten setzt ihr LoRa ein – wie gut funktioniert LoRa? Ist es ausreichend und zukunftsfähig?

Storbeck: LoRa ist definitiv zukunftsfähig und sinnvoll. Es lässt sich sehr schnell abdecken und hat gegenüber Kabeln den großen Vorteil, dass keine Tiefbauarbeiten notwendig sind. Natürlich gibt es hier auch Stellen, an denen die Sendefähigkeit aufgrund schlechter Funkverbindung eingeschränkt ist, aber das ist nur vereinzelt der Fall. Momentan sind etwa 90 Prozent aller Wärmehäuser mit Funk ausgestattet. Insgesamt sehen wir in LoRa eine gute Technologie, um bestehende Gebiete schnell umzurüsten. Das Netz kann damit in überschaubarer Zeit und mit normalem Aufwand auf Fernauslesbarkeit umgerüstet werden, ohne dass tiefbauliche Maßnahmen durchzuführen sind oder aufwendige Übertragungstechnik installiert werden muss. Zudem ist die Technik nicht auf einen spezifischen Anwendungsfall beschränkt, sondern vielseitig einsetzbar.

dena: Wie ist die Rolle des Smart Meter Gateways in eurem Betrieb?

Storbeck: Im Strombereich haben wir den Smart Meter Gateway Rollout schon fast flächendeckend umgesetzt. Perspektivisch planen wir, dass Wärme eher nicht an das Smart Meter Gateway angeschlossen wird, sondern dass eine eigenständige Kommunikation bestehen wird.

dena: Wie habt ihr die datentechnische Erfassung neuer Erzeugungsanlagen, speziell Wärmepumpen, umgesetzt und welche Schwierigkeiten sind dabei aufgetreten?

Storbeck: Die Inbetriebnahme und der Bau der Wärmepumpen haben sich aufgrund von Lieferengpässen verzögert, die es insbesondere bei der Schalttechnologie gab. Solche Verzögerungen sind typisch und können immer auftreten. Die Verzögerung lag jedoch nicht an der Datenverfügbarkeit selbst. Nach dem Bau haben wir einen „digitalen Zwilling“ in der Netzleitstelle erstellt. Dieses Vorhaben erforderte eine umfangreiche Datenaufbereitung und den Aufbau des gesamten Schaltbilds, was sich ebenfalls verzögerte. Dies war unter anderem auf einen Mangel an personellen Ressourcen zurückzuführen.

dena: Was hat zu diesem Personalmangel geführt?

Storbeck: Für dieses Projekt wurde niemand zusätzlich eingestellt. Obwohl Forschungsprojekte eine gewisse Priorität genießen, hatten wir bereits vorher einen Ressourcenengpass, der sich auf dieses Projekt ausgewirkt hat. Dies ist aber nicht spezifisch dem Projekt geschuldet.

³ Ein Data Warehouse ist eine spezielle Art von Datenbanksystem, das in seiner klassischen Form weniger Skalierbarkeit und Flexibilität als eine moderne Datenbank aufweist. Cloud-basierte Data Warehouses der großen Anbieter haben diese Eigenschaften übernommen, sind aber gegebenenfalls mit höheren Kosten verbunden.

Herausforderungen bei Personal und Fachkräften



Im Unternehmen kann Skepsis gegenüber KI-Projekten aufkommen. Mit einer transparenten Kommunikation und klaren Zielsetzung kann diese überwunden werden.

dena: Wie ist die Akzeptanz von KI-Projekten innerhalb des Unternehmens?

Storbeck: Die Akzeptanz ist insgesamt sehr gut. Das Interesse an den Projekten ist groß und wir müssen wenig Überzeugungsarbeit leisten. Unsere Mitarbeiterinnen und Mitarbeiter sind motiviert, sich an Forschungsprojekten zu beteiligen. KI wird als Zukunftsthema gesehen und von der Geschäftsführung ist gefordert, Wissen aufzubauen.

dena: Gibt es Lager innerhalb des Unternehmens, die eine andere Meinung zur KI haben?

Storbeck: Es gibt vereinzelt Skepsis, allerdings niemanden, der sich komplett verschließt.

dena: Wie wird eine solche Skepsis überwunden?

Storbeck: Wir zeigen den Mehrwert der KI-Projekte auf, insbesondere die Entlastung, die sie bringen können. Es ist normal, dass Angst vor dem Unbekannten und vor Veränderungen besteht. Wenn wir jedoch konkrete Anwendungsfälle präsentieren, verschwindet die Skepsis oft, da der Mehrwert so vielversprechend ist. Die Skepsis liegt eher in der Umsetzung und der Frage, wie weit automatisiert werden kann.

Energiepolitische Herausforderungen



Der Einsatz von KI-basierten Tools erfordert teils ein gewisses Vertrauen auf das Ergebnis, da die Lösungswege beispielsweise in einem Künstlichen Neuronales Netz nicht nachvollziehbar sind. Dieses Vertrauen wird heute bereits in vorhandene Lösungen gesetzt. Auch bei KI-basierten Lösungen gibt es Sicherheitsvorkehrungen, wobei die Versorgungssicherheit stets priorisiert wird.

Bei der Erstellung von Transformationsplänen im Rahmen der kommunalen Wärmeplanung können präzise Prognosen und eine Erzeugereinsatzoptimierung dabei helfen, geeignete Szenarien aufzustellen.

dena: Kommen wir zu den energiepolitischen Herausforderungen. Habt ihr schon Erfahrungen hinsichtlich des Themas Haftungsfragen bei der Anwendung von KI-Lösungen machen können?


Storbeck: Wenn es um Versorgungssicherheit geht, sind die Stadtwerke aufgrund der Lieferverträge mit den Kunden letztlich immer in der Verantwortung. In den Verträgen wird zwar keine 100-prozentige unterbrechungsfreie Versorgung versprochen, sondern ein bestimmter zu erreichender Anteil. Beim Einsatz von KI liegt die Haftungsfrage dennoch bei den Stadtwerken. Die Art der Versorgung spielt dabei keine Rolle. Eine Frage, die sich im Zusammenhang mit der Einsatzoptimierung stellt, ist: Was passiert, wenn eine Prognose für die Einsatzplanung falsch ist? In Gesprächen mit Dienstleistern stellte sich heraus, dass die Versorgungssicherheit dann immer Vorrang hat. Das heißt, wenn mehr Wärme benötigt wird, wird mehr Wärme produziert, unabhängig von einer KI-basierten Prognose.

dena: Gibt es denn Vertrauen auf KI-Prognosen, ohne dass es eine vollständige Nachvollziehbarkeit des Lösungsweges gibt?

Storbeck: Eher ja. Schon heute läuft die Wärmesteuerung über Algorithmen, welche ohne menschliche Eingriffe ablaufen. Daher sehe ich keine Notwendigkeit, genau zu verstehen, wie bestimmte Lösungen zustande kommen. Nur sollten die Auswirkungen und Handlungen nachvollziehbar und sichtbar sein.

dena: Kommen wir zum Thema Kommunale Wärmeplanung. Gibt es hier Herausforderungen? Gibt es Transformationspläne?

Storbeck: Die Kommunale Wärmeplanung und Transformationspläne laufen parallel. KWP ist in Schleswig-Holstein schon verpflichtend für Kommunen. Bis Ende 2024 muss die Kommune fertig sein. Damit die Kommunale Wärmeplanung innerhalb der Kommunen nichts entwirft, was gegen die Wärmestrategie der Stadtwerke läuft, sind wir eine Kooperation mit der Stadt eingegangen, um mitzuarbeiten. Dazu holen wir noch einen Dienstleister mit ins Boot.



Das Ganze läuft schon seit 1,5 Jahren und steht kurz vor dem Abschluss, einschließlich Potenzialanalyse und Maßnahmenpaket. Momentan findet noch der Feinschliff der Maßnahmen statt.

Die KWP betrachtet, wie die Kommune in Zukunft die Wärme- und Kälteplanung klimaneutral organisieren kann. Die Fernwärme wird dabei nicht die einzige Lösung sein. Ich denke, dass es zukünftig ein Drittel Fernwärme und zwei Drittel andere Lösungen geben wird. Bei der Fernwärme sind wir als Stadtwerke betroffen. Hier gibt es einen Transformationsplan nach der BEW-Förderung, den wir fast parallel gestartet haben. Wir haben uns bewusst dagegen entschieden, die KWP abzuwarten und dann den Transformationsplan aufzusetzen, um nicht ein, zwei Jahre Zeit zu verlieren. Die Machbarkeitsstudie lief also parallel und soll bis September 2024 fertig werden. Dort sind alle Maßnahmen zur Dekarbonisierung beschrieben. Geothermie, Abwärmenutzung, Luftwärmepumpen oder Einsatz von Abwärme aus Wasserstoffherzeugung liefern uns hier vielfältige Potenziale.

dena: Wie erstellt ihr den Transformationsplan? Wird er szenarienbasiert erstellt?

Storbeck: Normalerweise würde man für den Transformationsplan der Netze mehrere Szenarien durchrechnen. Bei der Größe unseres Netzes wird es aber nur ein Szenario geben. Es ist so groß, dass man am Ende nicht verschiedene Maßnahmen gegeneinander abwägen kann, sondern alles umsetzen muss, um die Ziele zu erreichen. Wir haben aber ein System, das das Netz als Modell mit Hauptleitungen und Wärmeerzeugern abbildet. Damit kann simuliert werden, wie die Jahreslast unter Berücksichtigung der umgesetzten Maßnahmen aussehen könnte. Damit wird dann der Jahreslastgang für die Jahre hochskaliert.

Zukünftig wollen wir uns verstärkt dem Thema Einsatzoptimierung und Prognosen widmen. Bereits vor dem Projekt haben wir daran gearbeitet, jedoch hat sich die Notwendigkeit durch das Projekt noch weiter erhöht. Unser Ziel ist es, dies im Laufe des Jahres aufzubauen. Zum einen möchten wir auf der technischen Seite ermöglichen, dass die Anlagen Fahrpläne abfragen können, und zum anderen wollen wir zuverlässige Prognosen erstellen. Derzeit suchen wir nach geeigneten Anbietern. Unser Wunsch ist außerdem, Simulationen mit zukünftigen Anlagen zu erstellen, um bessere Prognosen zu entwickeln. Zudem planen wir, einen neuen Mitarbeiter einzustellen, der sich ausschließlich um dieses Thema kümmert, da es für uns von hoher Bedeutung ist.

Operative Herausforderungen

FVU stehen vor einer Vielzahl an Herausforderungen. In Hinblick auf die Transformation der Fernwärmenetze ergeben sich insbesondere in der Netzhydraulik große Herausforderungen, die durch den Einsatz KI-basierter Tools überwunden werden können.



dena: Welche Herausforderungen gibt es zum Thema hydraulische Engpässe?

Storbeck: Das Thema Hydraulik stellt uns vor zunehmende Herausforderungen. Hier sehen wir einen typischen Anwendungsfall für KI-basierte Lösungen. Mit dem stetigen Wachstum unseres Netzes, insbesondere durch die Kommunale Wärmeplanung, kommen um die 100 bis 200 neue Anschlüsse pro Jahr dazu. Zudem werden wir die Netze mehr verbinden und vermehrt dezentrale Erzeuger einbinden. Einige davon werden dann an Stellen sein, die nicht ideal fürs Netz sind, aber trotzdem hydraulisch funktionieren müssen. Die Steuerung der verschiedenen Erzeuger stellt also eine Herausforderung dar, die zukünftig noch komplexer wird. Wir haben hier zwar schon Automatisierungen implementiert, benötigen aber immer noch händische Eingriffe.

Zukünftig müssen außerdem auch an Schlechtpunkten Anlagen laufen, da der Transport der Wärme durchs ganze Netz keine sinnvolle Lösung ist. Ein alternativer Ansatz über den schon diskutiert wird, wäre es, Pumpstationen im Netz zu installieren, die nur für die Druckverteilung da sind. So lässt sich eine Sicherstellung der Volumenströme gewährleisten, ganz ohne neue Erzeugung. All das wird irgendwann jedoch eine Größenordnung erreichen, die händisch nicht mehr zu kontrollieren ist. Neben der Aufbereitung der Schlechtpunkte werden noch viel mehr Messpunkte benötigt.

dena: Also ist die Hydraulik hinsichtlich der Integration von erneuerbaren Energien und Abwärme eine der größten Herausforderungen?

Storbeck: Ja, die Hydraulik stellt definitiv eine riesige Herausforderung dar. Besonders bei der Einbindung von Wärmepumpen und der Anpassung von Vorlauftemperaturen stoßen wir auf komplexe Fragestellungen. Auch kundenseitig gibt es im Hinblick auf die Hydraulik Herausforderungen. Die Netze, die vor vielen Jahren gebaut wurden, waren ausgelegt auf 100 Grad Celsius Vorlauftemperatur. Aufgrund von bestehenden Lieferverträgen können wir aber nicht von den Kunden einfach eine Reduktion der Temperaturen verlangen.

dena: Was könnte im Hinblick auf Digitalisierung helfen?

Storbeck: Was helfen wird, ist das Digitalisieren der ganzen Überwachung sowie der Kundenverbräuche und Temperaturen. Wir haben jetzt ca. 90 Prozent des Netzes mit LoRa ausgestattet. Darüber laufen die Daten in das Backend eines Portals. Im Zuge des Projektes haben wir ein Frontend mit Dashboard aufgebaut, um das Monitoring zu verbessern und die Störungsdienste effizienter zu gestalten. Denkt man hier weiter, könnte man fast eine Dienstleistung für die Wohnungswirtschaft daraus machen. Wir könnten anhand der Daten überwachen und bei Störungen direkt Installateure informieren.

dena: Welche Herausforderungen gibt es zum Thema Leckagen?

Storbeck: Die Überwachung von Leckagen ist zwar interessant, aber auch sehr aufwändig. Es fehlt noch an einem klaren Umsetzungsansatz. Es ist notwendig, mehr Messtechnik einzusetzen, um Daten zu erfassen, insbesondere da die Netze immer größer werden. Wir verfügen bereits über ein Leckagesystem zur Überwachung, allerdings erfolgt die Messung noch manuell. Wir sind jedoch bereits im Gespräch mit Herstellern, um Möglichkeiten zur Automatisierung zu erkunden. Derzeit sind wir im Prozess, das gesamte Netz zu erfassen, und erarbeiten Konzepte für eine automatisierte Überwachung.

dena: Wie sieht es beim Thema Netzkapazitäten aus?

Storbeck: Auch das ist ein relevanter Bereich für uns. Die Erzeugungsmenge muss immer zur Abnahme passen und kontinuierlich überprüft werden. Hier gibt es definitiv Überlegungen, eine dauerhafte Messung zu integrieren.

Handlungsempfehlungen

dena: Welche Handlungsempfehlungen würdest du Stadtwerken geben?

Storbeck: Das Wichtigste ist, so früh wie möglich ein Data Warehouse zu schaffen. Auch wenn solche datenintensiven Projekte erst in Zukunft geplant sind, sollte man alle Energiedaten in überlegter Struktur an einer Stelle gesammelt und verfügbar haben.

dena: Welche Handlungsempfehlungen oder Wünsche hast du an den Regulator?

Storbeck: Mir ist vor allem die Würdigung der netzdienlichen Arbeit wichtig. Sei dies durch Netzentgelte oder Steuern der Fall. Bei der gesamten Transformation des Fernwärmenetzes ist außerdem die Transparenz der Fernwärme und Preise zentral. Es muss berücksichtigt werden, dass jedes Netz anders ist. Mein Wunsch lautet daher, dass es keinen regulierten Markt geben soll, in dem Preise vorgegeben werden.

dena: Hast du Handlungsempfehlungen oder Wünsche an IT-Dienstleister?

Storbeck: Ich könnte mir vorstellen, dass Standardprodukte für mittlere und kleine Stadtwerke eine enorme Hilfe bei der Transformation des Netzes darstellen könnten. Nicht jedes Stadtwerk braucht individuelle Tools und kann gewährleisten, diese allein zu implementieren.

dena: Hast du Handlungsempfehlungen oder Wünsche an die Forschung?

Storbeck: Mir ist wichtig, dass wir uns bei diesen Themen kontinuierlich weiterentwickeln und die Chancen, die KI uns ermöglicht, nutzen.

dena: Als abschließende Frage: Wie habt ihr das Projekt erlebt?

Storbeck: Das Projekt war für uns in vielerlei Hinsicht erfolgreich. Zum einen haben wir uns erstmals mit dem Einsatz von KI in der Energieversorgung beschäftigt, dies hat Türen für zukünftige Anwendungen geöffnet, uns aber auch geschult. Insbesondere bei den vorbereitenden Themen, wie Datenbereitstellung, Schnittstellen etc. haben wir viel gelernt. Aber auch das Thema der Anwendbarkeit hat uns weitergebracht und neue Ideen hervorgerufen. So haben wir zukünftig eine Stelle, die sich nur mit der Optimierung unserer Erzeugung beschäftigen und dieses Thema voranbringen soll.

dena: Das freut uns! Wir konnten ebenfalls viel lernen und hoffen, dies auch in unserem Leitfaden adäquat weiterzuvermitteln. Vielen Dank für die sehr spannenden Einblicke.



5.

**Handlungs-
empfehlungen**

Aus dem Projekt lassen sich wertvolle wesentliche Handlungsempfehlungen zum einen für FVU und zum anderen für Anbieter von KI-Lösungen ableiten. Diese Handlungsempfehlungen für KI-basierte Projekte im Bereich der Wärmenetze wurden auf Basis der entwickelten Anwendungsfälle, des Leitfadens sowie der im Rahmen des Projekts identifizierten Herausforderungen erarbeitet. Die Handlungsempfehlungen sollen FVU dabei helfen, frühzeitig die richtigen Entscheidungen zu treffen, um die digitale Transformation zu beschleunigen, den Einsatz digitaler Technologien zu ermöglichen und somit für die bevorstehenden Aufgaben im Rahmen der Energiewende vorbereitet zu sein. Zudem sollen sie sowohl Start-ups als auch etablierten KI-Lösungsanbietern Ansätze für eine nachhaltige Produktentwicklung aufzeigen.

Fernwärmeversorgungsunternehmen

- **Aufbau einer umfassenden Datengrundlage (Primär- & Sekundärseite):** Der Aufbau einer umfassenden und zuverlässigen Datengrundlage ist unerlässlich. Diese sollte sowohl Daten direkt aus der Wärmezeugung und den Fernwärmenetz als auch Daten aus den Hausübergabestationen auf der Sekundärseite beinhalten und fortlaufend erhoben werden, um eine umfassende Datenhistorie aufzubauen. Datengetriebene Anwendungen wie KI-Modelle liefern bessere Ergebnisse, je umfassender und qualitativer die Datengrundlage ist.
- **Entwicklung einer Datenstrategie:** Eine klare Datenstrategie ist entscheidend für den erfolgreichen Einsatz von KI in Fernwärmenetzen. Diese Strategie sollte festlegen, welche Daten gesammelt werden, wie diese Daten erhoben werden und woher sie stammen. Zudem muss definiert werden, wer Eigentümer der Daten ist und wer die Verantwortung für deren Verwaltung trägt. Alle relevanten Akteure sollten in diesen Prozess einbezogen werden, um eine umfassende und nachhaltige Datenstrategie zu gewährleisten. Eine gute Datenstrategie hilft dabei, die digitale Transformation strukturiert umzusetzen und wesentlich mehrwertstiftende Prozesse zu priorisieren.
- **Modernisierung der Erhebung von Netzdaten:** Zur Erhebung von Netzdaten in Fernwärmenetzen sollte frühzeitig in geeignete fernauslesbare Messtechnik investiert werden. Diese Technologien ermöglichen eine effiziente und kostengünstige Sammlung von Netzdaten, was zu einer verbesserten Datenqualität und -verfügbarkeit führt und somit die Grundlage für KI-gestützte Optimierungen bildet.
- **Einsatz von SMGWs zur Übertragung von Erzeugungs-, Netz- und Verbrauchsdaten:** Für eine erfolgreiche Sektorenintegration ist die Steuerung von Heizanlagen und die damit ermöglichte Bereitstellung von Flexibilitäten für den Stromsektor von entscheidender Bedeutung. Damit einhergehend sind besondere Sicherheitsanforderungen an das Kommunikationsmodul zu beachten. Außerdem muss

eine hohe Interoperabilität mit der bestehenden Messinfrastruktur gewährleistet werden. Durch die gebündelte Übertragung verschiedener Messwerte aus unterschiedlichen Sparten können Synergieeffekte erzielt werden, um die Kosten der Digitalisierung sowohl für Betreiber als auch für Verbraucher möglichst gering zu halten. Diese Anforderungen werden durch das SMGW erfüllt.


- **Modernisierung der Datenbanken:** Bestehende Datenbanksysteme sollten modernisiert und beispielsweise zu leistungsfähigen Data Warehouses oder Datenplattformen weiterentwickelt werden. Diese modernen Datenbanken ermöglichen eine effiziente Speicherung, Verwaltung und Analyse großer Datenmengen, was essenziell für den Einsatz von KI in Fernwärmenetzen ist.
- **Etablierung einheitlicher Datenschnittstellen und -formate:** Einheitliche Datenschnittstellen und -formate (zum Beispiel APIs) sind entscheidend für die Integration und Interoperabilität verschiedener Systeme und Anwendungen. Durch die Standardisierung wird sichergestellt, dass Daten problemlos zwischen unterschiedlichen Systemen ausgetauscht und von KI-Anwendungen verarbeitet werden können.
- **Förderung einer positiven Unternehmenskultur in Bezug auf KI:** Um die Akzeptanz und den erfolgreichen Einsatz von KI in Fernwärmenetzen zu fördern, sollte eine positive Unternehmenskultur entwickelt werden. Dies umfasst den Abbau von Skepsis gegenüber KI-Anwendungen durch die Demonstration ihrer positiven Auswirkungen auf die Effizienz und Zuverlässigkeit der Fernwärmenetze. Mitarbeiterinnen und Mitarbeiter sollten über die Vorteile und Möglichkeiten, aber auch die Risiken von KI informiert und in deren Anwendung geschult werden, um eine breite Unterstützung und Motivation zu gewährleisten.

KI-Lösungsanbieter

- **Mit offenen Standards arbeiten:** Offene Schnittstellen und Formate gewährleisten eine reibungslose Integration und Interoperabilität verschiedener Systeme und Anwendungen. Dies erleichtert die Migration bestehender Systeme auf neue Technologien und stellt sicher, dass Daten und Dienste nahtlos miteinander kommunizieren können. Offene Standards fördern zudem die Flexibilität und Skalierbarkeit der Lösungen, was für die kontinuierliche Weiterentwicklung und Optimierung der Fernwärmenetze durch KI entscheidend ist.
- **Standardprodukte schaffen:** Die Entwicklung spezifischer, nicht übertragbarer Lösungen sollte, soweit möglich, vermieden werden. Dort, wo es möglich ist, sollten Branchenstandards geschaffen werden. Dadurch können Vendor-Lock-In-Effekte vermieden und die gesamtwirtschaftlichen Kosten der digitalen Transformation gesenkt werden.

- **Ökonomischen und ökologischen Nutzen priorisieren:** Sensorik muss zu einer Kosten- und/oder Emissionsenkung führen, um ihren Einsatz zu rechtfertigen. Innovationsstreiber müssen Technologien entwickeln, die zunächst auch mit einer limitierten bzw. variierenden Datenbasis umgehen können und basierend darauf einen Mehrwert liefern.
- **Europäische Leitplanken bei der Entwicklung von KI-Lösungen beherzigen:** KI-Lösungsanbieter müssen sich bereits bei der Entwicklung der Algorithmen Gedanken zu den zentralen Schlagworten der OECD machen und die Anforderungen des AI-Acts gemäß der Risikostufe proaktiv mitdenken und berücksichtigen.

Die Digitalisierung ist ein essenzieller Schritt zur Transformation des Energiesystems und zur Erreichung der Klimaziele. Methoden der künstlichen Intelligenz können auf allen Ebenen der Energieversorgung eingesetzt werden, um substantielle Mehrwerte zu liefern. Dabei ist ein systematisches Vorgehen insbesondere zur Schaffung günstiger Bedingungen erforderlich. Durch eine enge Zusammenarbeit zwischen FVU und KI-Lösungsanbietern können Hürden frühzeitig identifiziert und durch geeignete Maßnahmen mitigiert werden. Dieser Leitfaden soll dabei als Orientierung für eine erfolgreiche Zusammenarbeit auf Augenhöhe dienen.




Abbildungsverzeichnis

Abbildung 1: Circle of AI. Quelle: Eigene Darstellung in Anlehnung an RAUSCH Technology, 2024	19
Abbildung 2: KI-Anwendungsfälle. Quelle: Eigene Darstellung, dena, 2024	34
Abbildung 3: CRISP-DM Prozess-Diagramm. Quelle: Eigene Darstellung in Anlehnung an Wirth, 2000	37
Abbildung 4: Korrelationsmatrix für Kraftwerksdaten. Quelle: Eigene Darstellung, dena, 2024	42
Abbildung 5: Zusammenführung unterschiedlicher Datenquellen, -typen und Schnittstellen. Quelle: Eigene Darstellung, dena, 2024	45
Abbildung 6: Lastgang über 24 Stunden. Gemessene Leistung und Baseline „morgen wie heute“. Quelle: Eigene Darstellung, dena, 2024	46
Abbildung 7: Lastgang Fernwärmenetz über 24 h. Darstellung und Vergleich von Vorhersagemodellen (LSTM+MLP und Baseline) und Messwerten. Quelle: Eigene Darstellung, dena, 2024	49

Tabellenverzeichnis

Tabelle 1: Vor- und Nachteile der Kommunikationstechnologien (Lora Alliance, 2024; Deutsche Telekom AG, 2024, Sagemcom Broadband SAS, 2024)	15
Tabelle 2: Vergleich der Genauigkeit verschiedener Methoden. Quelle: Eigene Darstellung, dena, 2024	50



Literaturverzeichnis

AGFW (Der Energieeffizienzverband für Wärme, Kälte und KWK e. V.) (2023): Hauptbericht. Frankfurt am Main, Dezember 2023. Online verfügbar unter: <https://www.agfw.de/zahlen-und-statistiken/agfw-hauptbericht>

BDEW (Bundesverband der Energie- und Wasserwirtschaft e. V.) (2020): Künstliche Intelligenz für die Energiewirtschaft. Online verfügbar unter: https://www.bdew.de/media/documents/BDEW_KI_LAUNCH_2406_1ADiAzP.pdf

BDEW (Bundesverband der Energie- und Wasserwirtschaft e. V.) (2024): Entwicklung der Fernwärmenetze in Deutschland. Online verfügbar unter: <https://www.bdew.de/service/daten-und-grafiken/entwicklung-fernwaermenetze-deutschland/>, zuletzt geprüft am 11.10.2024

bitkom (Branchenverband der deutschen Informations- und Telekommunikationsbranche) (2019): Wirtschaftsschutz in der digitalen Welt. Online verfügbar unter: https://www.bitkom.org/sites/default/files/2019-11/bitkom_wirtschaftsschutz_2019_0.pdf

Das Europäische Parlament und der Rat der Europäischen Union (13.06.2024): VERORDNUNG (EU) 2024/1689 DES EUROPÄISCHEN PARLAMENTS UND DES RATES vom 13. Juni 2024 zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz und zur Änderung der Verordnungen (EG) Nr. 300/2008, (EU) Nr. 167/2013, (EU) Nr. 168/2013, (EU) 2018/858, (EU) 2018/1139 und (EU) 2019/2144 sowie der Richtlinien 2014/90/EU, (EU) 2016/797 und (EU) 2020/1828 (Verordnung über künstliche Intelligenz). Online verfügbar unter: <https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=CELEX:32024R1689>

dena (Deutsche Energie-Agentur GmbH) (2020): Künstliche Intelligenz – Vom Hype zur energiewirtschaftlichen Realität. Online verfügbar unter: https://www.dena.de/fileadmin/dena/Publikationen/PDFs/2020/dena_ANALYSE_Kuenstliche_Intelligenz_-_vom_Hype_zur_energiewirtschaftlichen_Realitaet_02.pdf

dena (Deutsche Energie-Agentur GmbH) (2023): Neue Energiebedarfe digitaler Technologien – Untersuchung von Schlüsseltechnologien für die zukünftige Entwicklung des IKT-bedingten Energiebedarfs. Online verfügbar unter: https://future-energy-lab.de/app/uploads/2023/10/ANALYSE_Neue_Energiebedarfe_digitaler_Technologien.pdf%C2%A0%C2%A0

dena (Deutsche Energie-Agentur GmbH) (2023): Regulatorische Modelle für eine klimaneutrale Fernwärme in Deutschland. Online verfügbar unter: <https://www.dena.de/infocenter/regulatorische-modelle-fuer-eine-klimaneutrale-fernwaerme-in-deutschland/>

dena (Deutsche Energie-Agentur GmbH) (2024): Grundlagen und Bedeutung von Datenräumen für die Energiewirtschaft. Online verfügbar unter: https://future-energy-lab.de/app/uploads/2024/04/dena_Bericht_Grundlagen-und-Bedeutung-von-Datenraeumen-fuer-die-Energiewirtschaft-dena-ENDA.pdf

dena (Deutsche Energie-Agentur GmbH) (2024): Studie: Energieeffiziente künstliche Intelligenz für eine klimafreundliche Zukunft. Neue Erkenntnisse über Energieeinsparpotenziale bei KI-Anwendungen. Online verfügbar unter: https://www.dena.de/fileadmin/dena/Publikationen/PDFs/2024/Studie_Energieeffiziente_kuenstliche_Intelligenz_fuer_eine_klimafreundliche_Zukunft.pdf

Deutscher Ethikrat (2023): Mensch und Maschine – Herausforderungen durch Künstliche Intelligenz. Online verfügbar unter: <https://www.ethikrat.org/fileadmin/Publikationen/Stellungnahmen/deutsch/stellungnahme-mensch-und-maschine.pdf>

Deutsche Telekom AG (2021): NB-IoT, LoRaWAN, Sigfox: ein aktueller Vergleich. Online verfügbar unter: <https://iot.telekom.com/de/downloads/mobile-iot-netzwerk-vergleich-nb-iot-lorawan-sigfox.pdf>

Deutsche Telekom AG (2024): Narrowband IoT_ schnell und energiesparend | IoT-Telekom. Online verfügbar unter: <https://iot.telekom.com/de/netze-tarife/narrowband-iot-lte-m, zuletzt geprüft am 11.10.2024>

DIN (Deutsches Institut für Normung e. V.); DKE (Deutsche Kommission Elektrotechnik) (2020): Deutsche Normungsroadmap Künstliche Intelligenz. Online verfügbar unter: <https://www.din.de/resource/blob/772438/6b5ac6680543eff9fe372603514be3e6/normungsroadmap-ki-data.pdf>

FFe(Forschungsstelle für Energiewirtschaft e. V.) (2020): Anwendungsfälle des supervised machine learning in der Energiewirtschaft. Online verfügbar unter: <https://www.ffe.de/veroeffentlichungen/anwendungsaelle-des-supervised-machine-learning-in-der-energiewirtschaft/>, zuletzt geprüft am 22.10.2024

Fraunhofer IEE (Fraunhofer-Institut für Energiewirtschaft und Energiesystemtechnik) (2022): Implementierungsleitfaden für den Einsatz von innovativen, datengetriebenen Anwendungen im Stromnetz. Online verfügbar unter: https://future-energy-lab.de/app/uploads/2023/01/Implementierungsleitfaden_120123.pdf

Géron, Aurélien (2023): Praxiseinstieg Machine Learning mit Scikit-Learn, Keras und TensorFlow, 3. Auflage: O'REILLY, 2023.

Finkenrath, Matthias (2021): KI-Anwendung in der Energietechnik: Einsatz maschineller Lernverfahren für die Wärmelastprognose. Online verfügbar unter: <https://opus4.kobv.de/opus4-hs-kempten/frontdoor/index/index/docId/1220>

Gramm, Stefanie; DNV (Det Norske Veritas) (2024): Wärmeplanungsgesetz – neue Pflichten für Betreiber von Fernwärmenetzen. Online verfügbar unter: <https://www.dnv.de/news/waermeplanungsgesetz-neue-pflichten-fur-betreiber-von-fernwaermenetzen/>, zuletzt geprüft am 10.10.2024

Kettemann, Matthias C. (2022): UNESCO-Empfehlung zur Ethik Künstlicher Intelligenz. Bedingungen zur Implementierung in Deutschland. Deutsche Unesco-Kommission (Hrsg.). Online verfügbar unter: https://www.unesco.de/sites/default/files/2022-03/DUK_Broschuere_KI-Empfehlung_DS_web_final.pdf

Lora Alliance. (2024): Online verfügbar unter: <https://lora-alliance.org>, zuletzt geprüft am 11.10.2024

Lund, Henrik; Østergaard, Poul Alberg; Nielsen, Tore Bach; Werner, Sven; Throsen, Jan Eric; Gudmundsson, Oddgeir; Arabkoohsar, Ahmad; Mathiesen, Brian Vad. (2021): Perspective on fourth and fifth district heating. Energy, Volume 227. Online verfügbar unter: <https://www.sciencedirect.com/science/article/pii/S0360544221007696?via%3Dihub>

Ortner, Sara; Pehnt, Martin; Ochse, Susanne. (2022): Kurzanalyse. Drittzugang bei Wärmenetzen. Umweltbundesamt (Hrsg.). CLIMATE CHANGE 32/2022 Ressortforschungsplan des Bundesministeriums für Umwelt, Naturschutz, nukleare Sicherheit und Verbraucherschutz. Online verfügbar unter: https://www.umweltbundesamt.de/sites/default/files/medien/479/publikationen/cc_32-2022_drittzugang_bei_waermenetzen_0.pdf

OECD (Organization for Economic Cooperation and Development) (2019): The Recommendation on Artificial Intelligence, OECD/LEGAL/0449. Online verfügbar unter: <https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449>

Rausch, Sven (2020): Ausfall- und Anomalieerkennung in Heizungsanlagen durch Machine-Learning Algorithmen. Universität Würzburg, 2020.

Russel, Stuart; Novig, Peter (2023): Künstliche Intelligenz. Ein moderner Ansatz, 4. Auflage: Pearson Studium, 2023.

Sagemcom Broadband SAS (2024): Siconia® SMARTY IQ-LTE. Online verfügbar unter: <https://www.sagemcom.com/de/energie-telekommunikation/sagemcom-dr-neuhaus/smart-meter-gateways-smgw/siconiar-smarty-iq-lte-konfiguriert-fuer-lan-eth-anschluss>, zuletzt geprüft am 11.10.2024

Shin, Won; Han, Jeongyun; Rhee, Wonjong (2021): AI-assistance for predictive maintenance of renewable energy systems. Online verfügbar unter: <https://www.sciencedirect.com/science/article/pii/S0360544221000244>

Umweltbundesamt (2024): Primärenergieverbrauch. Online verfügbar unter: <https://www.umweltbundesamt.de/daten/energie/primaerenergieverbrauch#definition-und-einflussfaktoren>, zuletzt geprüft am 11.10.2024

Umweltbundesamt (2024): Energieverbrauch für fossile und erneuerbare Wärme. Online verfügbar unter: <https://www.umweltbundesamt.de/daten/energie/energieverbrauch-fuer-fossile-erneuerbare-waerme>, zuletzt geprüft am 11.10.2024

UNESCO (United Nations Educational, Scientific and Cultural Organization) (2022): Recommendations on the Ethics of Artificial Intelligence. Online verfügbar unter: <https://unesdoc.unesco.org/ark:/48223/pf0000381137/PDF/381137eng.pdf.multi>

Wirth, Rüdiger; Hipp, Jochen (2000): CRISP-DM: Towards a standard process model for data mining. In Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining (Vol. 1, pp. 29-39)

WEF (World Economic Forum) (2021): Harnessing Artificial Intelligence to Accelerate the Energy Transition. Online verfügbar unter: https://www3.weforum.org/docs/WEF_Harnessing_AI_to_accelerate_the_Energy_Transition_2021.pdf

Zimmermann, Hendrik; Frank, David. (2019): Künstliche Intelligenz für die Energiewende: Chancen und Risiken. Germanwatch e. V. (Hrsg). Online verfügbar unter: www.germanwatch.org/de/17095

Abkürzungen

AI-Act	Artificial Intelligence Act
API	Application Programming Interface
BEG	Bundesprogramm zur Förderung von energieeffizienten Gebäuden
BEW	Bundesprogramm zur Förderung von effizienten Wärmenetzen
BHKW	Blockheizkraftwerk
BMWK	Bundesministerium für Wirtschaft und Klimaschutz
CAD	Computer Aided Design
CD	Continuous Deployment
CI	Continuous Integration
CICD	Continuous Integration and Continuous Deployment
CRISP-DM	Cross Industry Standard Process for Data Mining
CSV	Comma Separated Values
CV	Computer Vision
dena	Deutsche Energie-Agentur
DIN	Deutsches Institut für Normung
DKE	Deutsche Kommission Elektrotechnik Elektronik Informationstechnik
DSGVO	Datenschutz-Grundverordnung
DWD	Deutscher Wetterdienst
EEG	Erneuerbare-Energien-Gesetz
EEW	Bundesprogramm zur Förderung der Energie- und Ressourceneffizienz in der Wirtschaft
EDA	Explorative Datenanalyse
EnEfG	Energieeffizienzgesetz
ETL	Extract, Transform, Load
FVU	Fernwärmeversorgungsunternehmen
GEG	Gebäudeenergiegesetz
GPT	Generative pre-trained Transformer
GPU	Grafikprozessor
HAST	Hausanschlussstation
IEE	Intelligente Erzeugereinsatzplanung
IoT	Internet of Things
KNN	Künstlich Neuronales Netz
KPI	Key Performance Indicators
KWK	Kraft-Wärme-Kopplung
KWKG	Kraft-Wärme-Kopplungs-Gesetz
KWP	Kommunale Wärmeplanung
KWW	Kompetenzzentrum Wärmewende
KI	Künstliche Intelligenz
k-NN	k-Nearest Neighbor
LoRa	Long Range
LoRaWAN	Long Range Wide Area Network
LSTM	Long Short-Term Memory
LTE	Long Term Evolution
MSE	Mean Squared Error
MSR(-Technik)	Mess-, Steuerungs- und Regelungstechnik
MLP	Multilayer Perceptrons
MW	Megawatt
NB IoT	Narrow Band Internet of Things
NLP	Natural Language Processing
OECD	Organisation für wirtschaftliche Zusammenarbeit und Entwicklung
PLT	Prozessleittechnik
REST-API	Representational State Transfer – Application Programming Interface
SMARD	Strommarktdaten

SMGW	Smart Meter Gateway
TAB	Technische Abschlussbedingungen
UNESCO	United Nations Educational Scientific and Cultural Organization
UX	User-Experience (Benutzererfahrung)
WMZ	Wärmemengenzähler
WPG	Wärmeplanungsgesetz

Anhang

Tabellarische Aufstellung der Bewertung der KI-Anwendungsfälle

Anwendungsfälle	Mittelwert Komplexität	Standardabweichung Komplexität	Mittelwert Potenzial	Standardabweichung Potenzial
Langfristige betriebswirtschaftliche und technische Assetoptimierung	7,67	2,09	7,58	2,18
Optimierung Kundenanlage (Wirkung auf Primärseite)	5,25	1,74	6,67	2,21
Optimierung Kundenanlage (Wirkung auf Sekundärseite)	7,00	2,00	7,00	1,93
Optimierung des Netzbetriebs und der Netzhydraulik	6,82	2,04	6,91	2,35
Predictive Maintenance (Netzbetreiberseite)	6,25	2,01	6,67	2,21
Predictive Maintenance (Kundenseite)	7,00	2,09	5,82	2,62
Frühzeitige Störungserkennung an Kundenanlagen (kurzfristig)	5,56	2,01	5,11	2,13
Kapazitätsmanagement Netz und Erzeugung	7,00	2,00	7,36	1,15
Optimierung des Wärmeerzeugerbetriebs	6,73	1,60	8,36	1,55
Energetisches Monitoring (und Abgleich von Richtlinien)	5,00	1,73	3,75	1,39

