

Validierung eines KI-Modells zur Prognose von gebäudescharfen Heizwärmebedarfen für den Gebäudebestand des Landes Berlin

Christoph Nytsch-Geusen, Alexander Küster-Inderfurth, Stefanie Segbers
Universität der Künste Berlin, Institut für Architektur und Städtebau, Germany
E-Mail: nytsch@udk-berlin.de

Kurzfassung

Im Rahmen des Forschungsverbundprojektes EnergyMap Berlin (<https://energymap-berlin.de>) wurde zum Zwecke der Wärmeplanung ein KI-gestütztes schnelles Prognosemodell zur Bestimmung gebäudescharfer Heizwärmebedarfe für den Berliner Gebäudebestand (ca. 370.000 Gebäude) entwickelt und anhand realer Energieverbrauchswerte validiert. Das verwendete Prognosemodell besteht aus jeweils vier neuronalen Netzwerkmodellen für Wohngebäude und für Nichtwohngebäude und differenziert hierbei unterschiedliche Gebäudetypen und Gebäudegrößenklassen. Die verwendeten Trainingsdaten für die 8 Netzwerkmodelle wurden aus mehreren Millionen physikalisch basierter thermischer Gebäudesimulation mit SimStadt erzeugt, wobei Varianten mit unterschiedlichen Klimajahren, energetischen Bauteilkennwerten, Fensterflächenanteilen etc. berücksichtigt wurden.

Der vorliegende Beitrag fokussiert auf die Validierung des KI-Prognosemodells mittels realer Energieverbrauchsdaten. Die Validierung wurde in einem mehrstufigen hierarchischen Verfahren durchgeführt: In einem ersten Schritt wurde für ein ausgewähltes Einzelgebäude ein Vergleich von prognostizierten Bedarfen des KI-Modells mit Verbrauchswerten aus 15 Klimajahren vorgenommen. Im nächsten Schritt wurden auf Gebäudeblockebene für mehrere Blöcke aggregierte Prognosewerte mit Blockverbrauchswerten aus vier Klimajahren verglichen. Im letzten Schritt erfolgte ein Vergleich des prognostizierten Bedarfs für das gesamte Land Berlin und dem Gesamtheizenergieverbrauch seines Gebäudebestands.

Die Ergebnisse der Validierung zeigen, dass eine Vorhersage des Heizwärmebedarfs mit einem KI-Prognosemodell auf allen drei Ebenen grundsätzlich gut möglich ist. Eine größere Anzahl von Gebäuden und auch Blöcken zeigt aber nach wie vor erhebliche Abweichungen zwischen Energiebedarf und -verbrauch.

Einführung

In der letzten Dekade wurden zahlreiche Forschungsarbeiten durchgeführt, bei denen die berechneten Wärmebedarfe des Gebäudebestands von Stadtquartieren mit gemessenen Verbrauchsdaten systematisch verglichen wurden. Bei diesen Bedarfs- bzw. Verbrauchsvergleichen wurden unterschiedliche Modelle bzw. Methoden zur Ermittlung der Gebäudewärmebedarfe genutzt: diese wurden entweder hergeleitet über Gebäudearchetypen (kategorisiert nach Typ, Baualter, Nutzung und Sanierungszustand) oder wurden über eine physikalisch basierte Energiebilanzierung bzw. Energiesimulation berechnet. Die Bedarfs-/Verbrauchsvergleiche wurden sowohl auf Ebene des Einzelgebäudes (Dochev et al., 2018; Wyrwa et al., 2017; Moreno et al., 2024) bzw. auf übergeordneten Ebenen von Gebäudeblöcken oder noch stärker aggregiert auf größeren Rastern oder Postleitzahlgebieten (Moreno et al., 2024; Yang et al., 2020; Calderón et al., 2024; Wang et al., 2020; Schwanebeck et al., 2021) vorgenommen. Die modellierten Gebäudewärmebedarfe wurden hierbei mit netzgebundenen Verbrauchsdaten (Fernwärme, Gas) oder mit von Einzelgebäuden aggregierten Verbrauchsdaten verglichen. Im Ergebnis zeigen diese Validierungen auf den aggregierten Ebenen (Gebäudeblock, Stadtquartier- oder Postleitzahlebene) wesentlich geringere Abweichungen als auf der Ebene des Einzelgebäudes, da belastbare gebäudescharfe Angaben zum Sanierungsstand, zum Wohnungsleerstand, zum Nutzerverhalten, zu den Nutzungsgraden der Wärmeversorgungsanlagen häufig fehlen bzw. nur grob geschätzt werden können, aber diese unsicheren Angaben pro Einzelgebäude sich nach Aggregation auf höherer Ebene wieder vermitteln.

KI-Prognosemodell

Für das KI-Prognosemodell von EnergyMap Berlin wurde ein Satz von 8 neuronalen Netzwerkmodellen entwickelt, welche auf Basis von insgesamt 24 Eingabegrößen (Features) den jährlichen Heizwärmebedarf für den Gebäude-

bestand von Berlin gebäudescharf prognostizieren (Segbers et al., 2024). Zu den Features gehören Größen, welche aus der Gebäudegeometrie abgeleitet werden können (außenluftberührende Fassaden- und Dachflächen, angrenzende Fläche an Nachbargebäude, Fensterflächenanteile, beheiztes Gebäudevolumen, beheizte Nutzfläche, ...), Parameter zur Beschreibung der Energieeffizienz der Gebäudehülle (U-Werte für Fassade, Fenster, Dach und Bodenplatte), Parameter zur Beschreibung der Gebäudenutzung (insgesamt 5 Wohngebäude und 12 Nichtwohngebäudetypen) sowie Parameter zur Beschreibung des Außenklimas (historische Klimajahre und Klimawandelszenarien).

Trainingsprozess

Die Trainingsdaten für die neuronalen Netzwerkmodelle wurden durch skriptgesteuerte automatisierte thermische Gebäudesimulationen mit SimStadt (Weiler et al., 2021) erzeugt. Hierfür wurde für ein Großteil des Gebäudebestands von Berlin gebäudescharf der jährliche Heizwärmebedarf simuliert (ca. 291.000 Gebäude), wobei für jedes Gebäude auch noch Varianten berechnet wurden, bei denen der Sanierungszustand variiert wurde (nicht, teil- oder vollsanierte Gebäude, beschrieben durch bestimmte U-Wert-Kombinationen). Weiterhin wurden für alle Sanierungsvarianten auch die Klimajahre variiert (Jahre 2010 bis 2024 sowie Klimawandelszenarien RCP 2.6 und RCP 8.5 für die Jahre 2030, 2040 und 2100), wofür die Klimadaten der Referenz-Station des Deutschen Wetterdienstes (DWD) in Potsdam (Stations-ID 03987) genutzt wurde. Aus allen Varianten ergaben sich insgesamt ca. 15,6 Mio. Trainingsdatensätze.

Tabelle 1: Mit SimStadt erzeugte Trainingsdatensätze für die 8 neuronalen Netzwerkmodelle

Namen der Modelle	Beheizte Fläche (von/bis)	Trainingsdatensätze (inkl. versch. Szenarien)	Gebäudeanzahl, die in jedes Training eingeflossen sind
WG-1	<= 300	3.003.090	151.036
WG-2	> 300, < 1500	3.000.000	69.677
WG-3	>= 1500, <= 3000	2.873.592	25.971
WG-4	> 3000	2.283.714	14.786
NWG-1	<= 1000	1.845.664	12.629
NWG-2	> 1000, < 5000	1.698.220	11.719
NWG-3	>= 5000, <= 20000	756.408	4.924
NWG-4	> 20000	134.796	874
GESAMT		15.595.484	291.616

Da kleine Wohn- und Nichtwohngebäude in Berlin sehr viel häufiger als größere Gebäude vorkommen (vgl. Tabelle 1), wurde der Trainingsdatensatz auf 8 Teildatensätze aufgeteilt, um so innerhalb jeder Größenklasse bzgl. der beheizten Gebäudefläche gleichverteilte Trainingsdatensätze zu erhalten.

Mit diesen wurden insgesamt 8 neuronale Netzwerkmodelle (4 Wohngebäude- und 4 Nichtwohngebäude) mittels überwachtem Lernens trainiert.

Durch die Aufteilung auf mehrere Netzwerkmodelle lässt sich mit dem Prognosemodell auch die unterschiedliche Sensibilität bestimmter Eingangsgrößen auf die Ausgangsgröße des Heizwärmebedarfs sehr viel besser abbilden (z.B. hängt der Heizwärmebedarf kleiner Gebäude im Vergleich zu größeren Gebäuden sehr viel stärker von den U-Werten seiner außenluftberührenden Bauteile ab, da erstere relativ zum beheizten Gebäudevolumen eine sehr viel größere außenluftberührende Fassadenfläche aufweisen).

Abbildung 1 zeigt den Trainingsprozess der 8 Netzwerkmodelle anhand des Verlaufs des mittleren absoluten Fehlers bei der Prognose des jährlichen Heizwärmebedarfs.




Abbildung 1: Trainingsprozess der neuronalen Netzwerkmodelle des Prognosemodells. Oben: 4 Modelle für Wohngebäude, unten: 4 Modelle für Nichtwohngebäude

Demnach können die neuronalen Netzwerkmodelle die mit SimStadt simulierten Jahresheizwärmebedarfe mit einem Fehler zwischen 2 bis 8 Prozent wiedergeben, wobei der Fehler für kleine Wohngebäude mit einer beheizten Fläche kleiner 300 m² am kleinsten ist.

Ermittlung des Jahresheizenergiebedarfs

Für die Ermittlung des Heizenergiebedarfs eines Einzelgebäudes muss zusätzlich der Wärmebedarf für die Warmwasserbereitung sowie der Anlagennutzungsgrad der Wärmeversorgung mit einbezogen werden. Weiterhin spielt für eine realistische Prognose die Berücksichtigung von Rebound-Effekten bei der Wärmeversorgung von Gebäuden eine wesentliche Rolle.

1. Wärmebedarf Warmwasserbereitung: Zur Berechnung des Wärmebedarfs zur Warmwasserbereitung inkl. der Verteilverluste wurden im Prognosemodell in Anlehnung an die DIN 18599 Teil 10 nutzfächenspezifische Werte verwendet, welche insgesamt 23 verschiedene Gebäudekategorien berücksichtigen.

2. Anlagennutzungsgrad: aufgrund nicht vorhandener gebäudescharfer Daten zur

Anlagentechnik wurde je Gebäudeblock ein Anlagennutzungsgrad ermittelt, der die energetische Effizienz der Wärmeversorgung abbildet. Gebäudeblöcke, die ausschließlich mit Fernwärme versorgt werden, erhielten einen Anlagennutzungsgrad von 100 Prozent. Blöcke, die ausschließlich über eine Gasversorgung verfügen, ein Wert von 93 Prozent angesetzt. Für Blöcke mit einer Kombination aus Fernwärme- und Gasversorgung wurde das jeweilige Verhältnis der beiden Energieträger berücksichtigt. Daraus ergibt sich ein gestaffelter Anlagennutzungsgrad zwischen 93 Prozent und 100 Prozent, abhängig vom Anteil der effizienteren Fernwärme. Bei 4.615 von insgesamt 15.920 der Berliner Gebäudeblöcke lagen keine konkreten Blockverbrauchsdaten vor, für welche ein pauschaler Anlagennutzungsgrad von 95 Prozent angenommen wurde. Dies entspricht dem durchschnittlich berechneten Nutzungsgrad aus dem Verhältnis des gesamten Fernwärme- und Gasverbrauchs in Berlin.

3. Berücksichtigung der Rebound-Effekte: In der Literatur wurde der Rebound-Effekt bzgl. des Heizenergieverbrauchs unterschiedlich energieeffizienter Wohngebäude ausführlich untersucht (Haas et al., 2000; Guerra Santin, 2013; Aydin et al., 2017). Bei Wohngebäuden mit niedriger Energieeffizienz, also hohen spezifischen Heizenergiebedarfen, liegen die theoretisch berechneten Bedarfe meist sehr viel höher als die tatsächlichen Verbräuche, da i.d.R. aus ökonomischen Gründen nur selten eine Vollbeheizung dieser Gebäude über deren Nutzflächen und während des ganzen Tages erfolgt. Umgekehrt treten bei sehr energieeffizienten Gebäuden (Niedrigstenergie- oder Passivhaus-Gebäuden) teilweise höhere Verbräuche als berechnete Bedarfe auf, da diese Gebäude in der Heizperiode auf ein nicht optimales Nutzerverhalten sehr viel sensibler reagieren (z.B. Betrieb von Gebäudebereichen mit freier Fensterlüftung anstatt mit kontrollierter Lüftung mit Wärmerückgewinnung). Für die Berücksichtigung solcher Rebound-Effekte wurde in das Prognosemodell von EnergyMap Berlin eine Korrekturfunktion von (Loga, 2019), verwendet, welche aus den statistischen Untersuchungen an gemessenen Heizenergieverbräuchen von ca. 2.800 Wohngebäuden entnommen wurde (vgl. Abb. 2).

Diese nichtlineare Funktion ermittelt einen Korrekturfaktor, welcher für Gebäude mit einem spezifischen jährlichen Heizenergiebedarf kleiner 80 kWh/m²a den in Schritt 2 ermittelten gebäudescharfen Gesamtheizenergiebedarf vergrößert bzw. bei größeren spezifischen Heizenergiebedarfen reduziert.




Abbildung 2: Kalibrierungsfunktion zur Berücksichtigung der Rebound-Effekte nach (Loga, 2019)

Diese Korrekturfunktion, welche ausschließlich auf der statistischen Auswertung von Energieverbräuchen von Wohngebäuden abgeleitet wurde, wird im Prognosemodell nicht nur auf prognostizierten Heizwärmebedarfe der Wohngebäude, sondern mangels Literaturwerte ebenfalls zur Korrektur der Wärmebedarfe der Nichtwohngebäude verwendet, was methodisch noch eine Schwäche darstellt.

Validierung

Zur Validierung des KI-Prognosemodells auf Gebäudeebene und Blockebene wurde jeweils auf mehrjährige Endenergieverbrauchswerte zurückgegriffen. Auf Gebäudeebene stammen diese aus jährlichen Heizenergieabrechnungen eines Einzelgebäudes über 15 Jahre, welche innerhalb des Forschungsprojekts EnergyMap Berlin durch eine Datenspende erhoben wurden. Für dieses Gebäude standen auch noch weitere präzierte Gebäudeinformationen zur Verfügung (z.B. der exakte Wert der beheizten Gebäudefläche oder der U-Wert der Dachkonstruktion), welche als angepasste Eingabeparameter für das Prognosemodell genutzt werden konnten. Auf Blockebene wurden für die Validierung drei verschiedene Gebäudeblöcke verwendet, von denen einer im Stadtzentrum und die beiden anderen im äußeren Stadtbereich von Berlin liegt. Für die Validierung der Blöcke wurden die gebäudescharfen Prognosewerte der innerhalb eines Blockes gelegenen Blöcke aggregiert und mit den im Energieatlas Berlin veröffentlichten Blockendenergieverbräuchen der Jahre 2020 bis 2023 verglichen (<https://energieatlas.berlin.de>).

Berücksichtigung des städtischen Wärmeinsel-Effekts bei der Validierung

Bei der Erzeugung der Trainingsdaten mit SimStadt für die neuronalen Netzwerkmodelle von EnergyMap Berlin wurden die Klimadaten der Referenz-Station des Deutschen Wetterdienstes (DWD) in Potsdam (Stations-ID 03987) genutzt. Der Jahresmittelwert der Außenlufttemperatur betrug an diesem Standort

im Jahr 2025 10,6 °C und liegt damit im Jahresmittel um ca. 1,6 °C niedriger als im Stadtzentrum von Berlin (vgl. Abb. 3). Die Kartendarstellung wurde auf Grundlage der HOSTRADA-Wetterdaten des Deutschen Wetterdienstes (DWD) mit der von Autoren entwickelten Python-Bibliothek `hostrada4py` (<https://github.com/UdK-VPT/hostrada4py>) erzeugt und zeigt deutlich den Wärmeinsel-Effekt im Zentrum von Berlin. Die Bauteilmassen der erhöhten Bebauungsdichte im Berliner Stadtzentrum (vgl. Abb. 4) in Kombination mit einem hohen Bodenversiegelungsgrad speichern die solare Einstrahlung und die städtische Abwärme sehr viel besser als in den umgebenden, viele weniger dicht bebauten Stadtgebieten, was die Ungleichverteilung der Außenlufttemperatur im gesamten Stadtgebiet bewirkt.




Abbildung 3: Örtliche Verteilung der jahresmittleren Lufttemperatur in Berlin und Potsdam im Jahr 2025 (Datenquelle: HOSTRADA DWD)




Abbildung 4: Örtliche Verteilung der Bebauungsdichte pro Gebäudeblock im Stadtraum von Berlin (Datenquelle: EnergyMap Berlin)

Um die Auswirkung des Wärmeinseleffekts bei der Validierung des Prognosemodells auf Ebene des Einzelgebäudes und der Blockebene zu berücksichtigen, wurde ein Klimakorrekturfaktor eingeführt. Dieser wurde dann auf Basis der

HOSTRADA-Wetterdaten für die in der Validierung betrachteten Standorte und Klimajahre, für welche erhobene Endenergieverbrauchswerte vorlagen, bestimmt. Als Klimakorrekturfaktor KF wurde das Verhältnis der Jahresgradtage (JGT) des lokalen Standorts, zu den JGT des Referenzstandorts (Messstation 03987 in Potsdam), mit dessen Klimadaten das Prognosemodell von EnergyMap Berlin trainiert wurde, definiert:

$$KF = \frac{JGT(Lokal)}{JGT(Referenz)} \text{ in Kd/a} \quad (1)$$

Hierbei werden die Gradtage eines einzelnen Tages GT über den Mittelwert der Außenlufttemperatur an diesem Tag t_m bestimmt:

$$GT = (20^\circ C - t_m) \text{ in Kd falls } t_m < 15^\circ C$$

$$GT = 0 \text{ falls } t_m \geq 15^\circ C \quad (2)$$

Die Aufsummierung aller Gradtage über einen 12-Monatszeitraum ergeben die JGT.

Der Klimakorrekturfaktor KF wird dann zur Anpassung des vom KI-Modell prognostizierten Jahresheizenergiebedarfs verwendet:

$$Q_{prog,heiz,korr} = KF \cdot Q_{prog,heiz} \text{ in MWh/a} \quad (3)$$

Validierung auf Gebäudeebene

Für die Validierung wurde ein fünfgeschossiger Berliner Altbau (Baujahr 1905) mit Vorderhaus, Seitenflügel und Hinterhaus in Berlin-Pankow ausgewählt, für den jährliche Verbrauchswerte der Jahre 2010 bis 2024 vorlagen (vgl. Abb. 5).



Abbildung 5: Berliner Altbaugebäude in Berlin-Pankow für die Validierung am Einzelgebäude. Links: Straßenseite, oben rechts: ausgebauter Dachgeschoss; unten Mitte: Heizkostenabrechnung, unten rechts: Hoffassade

Abbildung 6 zeigt den Vergleich der prognostizierten Jahresheizenergiebedarfe auf Basis der statistischen Gebäudeinformationen aus der Datenbank von EnergyMap Berlin (mit und ohne Klimakorrektur) für die Jahre 2010 bis 2024 mit den entsprechenden Endenergieverbrauchswerten an Erdgas der gleichen Jahre aus den jeweiligen Heizkostenabrechnungen. In Abbildung 7 ist das Verhältnis des prognostizierten Jahresheizenergiebedarfs zu den Endenergieverbrauchswerten dargestellt.




Abbildung 6: Prognostizierte Jahresheizenergiebedarfe (mit und ohne Klimakorrektur) und Endenergieverbräuche am Einzelgebäude in MWh/a




Abbildung 7: Verhältnis prognostizierter Jahresheizenergiebedarfe (mit und ohne Klimakorrektur) zu den Endenergieverbrauchswerten beim Einzelgebäude

Demnach berechnet das KI-Prognosemodell ohne Klimakorrektur in allen Jahren einen systematisch höheren Bedarf an Erdgas als das Gebäude tatsächlich verbraucht hat. Durch die Einführung des Klimakorrekturfaktors, welcher je nach Jahr zwischen 0,852 und 0,904 schwankt (Mittelwert 0,884) verringert sich die mittlere Abweichung über alle 15 Verbrauchsjahre von plus 23 Prozent auf plus 9 Prozent.

Unter Hinzunahme weiterer vorliegender Informationen für dieses Gebäude können die Eingabeparameter gegenüber den statistischen Annahmen des Prognosemodells weiter präzisiert werden:

- ausgebauten Dachgeschoss: U_{Dach} : 0,25 W/m²K (statistische Annahme 1,66: W/m²K)
- beheizte Nutzfläche: 1.855 m² laut Heizkostenabrechnung (statistische Annahme: 1.713 m²)
- spez. Energiebedarf Trink-WW: 32 kWh/m²a laut Heizkostenabrechnung (statistische Annahme: 11 kWh/m²a)
- Anlagenwirkungsgrad: 96 Prozent, Gasbrennwert-Kessel (statistische Annahme: 93 Prozent)

Durch die Korrektur auf Grund des vorliegenden Gebäude-Zusatzwissens lassen sich Abweichungen zwischen Bedarfsprognose und Verbräuchen weiter verringern (siehe Abb. 8):




Abbildung 8: Verhältnis prognostizierter Jahresheizenergiebedarfe (mit und ohne Zusatzwissen) zu den Endenergieverbrauchswerten beim Einzelgebäude

Tendenziell berechnet das Prognosemodell etwas höhere Bedarfe an Erdgas als das Gebäude tatsächlich verbraucht hat:

- Abweichung langjähriges Mittel (2010 bis 2024): plus 3 Prozent (anstatt plus 8 Prozent)
- maximale Abweichung (2012): plus 22 Prozent (anstatt plus 40 Prozent)

Validierung auf Blockebene

Die Validierung auf Blockebene wurde anhand folgender drei Blöcke vorgenommen:

Block 111001 in Berlin Pankow: in diesem Block liegt auch das betrachtete Einzelgebäude. Der Block mit 28 beheizten Gebäuden ist Teil des ehemaligen Sanierungsgebiets „Winsviertel“ (1994 – 2011 flächendeckend saniert), geprägt durch einen Gebäudebestand, der überwiegend vor 1918 errichtet und durch einige Neubauten seit 1990 ergänzt wurde. Auf Grund der Quartierssanierung wird der Gebäudebestand des analysierten Blocks ausschließlich über Erdgas beheizt.




Abbildung 9: Block 111001 im Berliner Bezirk Pankow mit 28 beheizten Gebäuden (Quelle: Apple Karten und EnergyMap Berlin)

Der prognostizierte Bedarf liegt nach der Klimakorrektur (KF: 0,857 bis 0,894) im Mittel der Jahre 2020 bis 2023 ca. 11 Prozent unterhalb der Verbrauchswerte. Die Jahre 2022 und 2023 (jeweils minus 4 Prozent) werden deutlich genauer prognostiziert als die Jahre 2020 und

2021 (minus 15 Prozent und minus 20 Prozent), siehe Abb. 10.




Abbildung 10: Prognostizierte Jahresheizenergiebedarfe (mit und ohne Klimakorrektur) und Endenergieverbrauch des Blocks 111001 in MWh/a

Block 126612 in Berlin Treptow-Köpenick: Der Block mit 8 beheizten Mehrfamilienhäusern wurde in den 1990er-Jahren als zusammenhängendes Gebäudeensemble erbaut und wird ausschließlich über Fernwärme beheizt.




Abbildung 11: Block 126612 im Berliner Bezirk Treptow-Köpenick mit 8 beheizten Gebäuden (Quelle: Apple Karten und EnergyMap Berlin)




Abbildung 12: Prognostizierte Jahresheizenergiebedarfe (mit und ohne Klimakorrektur) und Endenergieverbrauch des Blocks 126612 in MWh/a

Der prognostizierte Bedarf liegt nach der Klimakorrektur (KF: 0,916 bis 0,974) im Mittel der Jahre 2020 bis 2023 ca. 6 Prozent oberhalb der Verbrauchswerte, die Jahre 2022 und 2023 (plus 17 Prozent und plus 10 Prozent) werden ungenauer prognostiziert als die Jahre 2020 und 2021 (plus 4 Prozent und minus 4 Prozent), siehe Abb. 12.

Block 143058 in Berlin Treptow-Köpenick: Der Block mit 7 beheizten Mehrfamilienhäusern wurde in den 1980er-Jahren erbaut und wird ebenfalls ausschließlich über Fernwärme beheizt.



Abbildung 13: Block 143058 im Berliner Bezirk Treptow-Köpenick mit 7 beheizten Gebäuden (Quelle: Apple Karten und EnergyMap Berlin)




Abbildung 14: Prognostizierte Jahresheizenergiebedarfe (mit und ohne Klimakorrektur) und Endenergieverbrauch des Blocks 126612 in MWh/a

Der prognostizierte Bedarf liegt nach der Klimakorrektur (KF: 0,970 bis 0,986) im Mittel der Jahre 2020 bis 2023 ca. 13 Prozent oberhalb der Verbrauchswerte, die Jahre 2022 und 2023 (jeweils plus 21 Prozent) werden ungenauer prognostiziert als die Jahre 2020 und 2021 (plus 12 Prozent und plus 1 Prozent), siehe Abb. 14.

Validierung auf Stadtebene

Der letzte Schritt stellt den Versuch einer Validierung auf der Ebene der Gesamtstadt Berlin dar. Ein Vergleich auf dieser Ebene von Energiebedarfsprognosen mit Energieverbräuchen ist mit großen Unsicherheiten behaftet, da sowohl die statistische Datenbasis von EnergyMap Berlin als auch die Datenbasis für die Energieverbräuche des Berliner Energieatlas für eine Vielzahl von Blöcken derzeit noch fehlerhaft und unvollständig sind (siehe Abschnitt „Ergebnisanalyse und Diskussion“). Der Vergleich wurde hauptsächlich für eine Plausibilitätskontrolle des KI-Prognosemodells von EnergyMap Berlin vorgenommen.

Der Gebäudebestand von Berlin umfasst ca. 338.000 Wohngebäude und ca. 31.000 Nichtwohngebäude und ist in ca. 15.920 Blöcke gegliedert. Abb. 15 zeigt den gesamten Gebäudebestand im Web-Interface von EnergyMap Berlin.




Abbildung 15: Darstellung des Berliner Gebäudebestands im Web-Interface von EnergyMap Berlin

Für den Vergleich wurde das Verhältnis Prognose zu Verbrauch für alle Blöcke von Berlin als statistische Verteilung betrachtet. Für jeden Gebäudeblock wurde hierfür der prognostizierte klimabereinigte Blockbedarf von EnergyMap Berlin durch den klimabereinigten Block-Bedarfswert aus dem Energieatlas Berlin des Jahres 2020 verglichen (Abb. 16).




Abbildung 16: Validierung auf Stadtebene: Häufigkeitsverteilung des Verhältnisses Blockverbrauch EnergyMap Berlin zu Blockverbrauch Energieatlas Berlin 2020 (Prognose- und Verbrauchswerte klimabereinigt)

In der Summe überschätzt EnergyMap Berlin die Blockverbräuche um ca. 8 Prozent. Die größte Klassenhäufigkeit (0,95 – 1,025) mit 939 Blöcke befindet sich im Schwerpunkt der Verteilung. Etwa die Hälfte aller Blöcke (5.563 Blöcke bzw. 49 Prozent) befinden sich im Bereich 0,725 bis 1,25. 384 Blöcke zeigen eine sehr große Überschätzung des Bedarfs größer 500 Prozent (vgl. Abb. 16).

Ergebnisanalyse und Diskussion

Validierung auf Gebäudeebene

Das KI-Prognosemodell von EnergyMap Berlin kann die realen Endenergieverbrauchswerte an Erdgas für das betrachtete Einzelgebäudes über in den meisten der betrachteten 15 Jahre in der Prognose gut wiedergeben, wobei die Klimakorrekturen für den lokalen Standort die Prognosegenauigkeit nochmals deutlich verbessern kann. Zusatzwissen über den energetischen Zustand des Einzelgebäudes oder die genaue Größe der beheizten Fläche, was

Nutzern oder Gebäudeeigentümern i.d.R. zur Verfügung steht, kann die Prognosegenauigkeit nochmals verbessern, was dann beim betrachteten Gebäude im langjährigen Mittel den Verbrauch um nur noch 3 Prozent überschätzt.

Validierung Blockebene

Die Validierung auf Blockebene wurde für drei Blöcke in Berlin mit unterschiedlichem Lokalklima durchgeführt, ein Block in einem tendenziell wärmeren Innenstadtklima und für zwei weitere Blöcke in einer eher kühleren Randlage von Berlin. Auf Ebene der Blöcke können für die KI-Prognosen nur die statistischen Gebäudeparameter aus der EnergyMap Berlin-Datenbank genutzt werden, da auf dieser Ebene kein Zusatzwissen über die Gebäude vorliegt. Die erzielbare Prognosegüte liegt daher etwas niedriger, die Blockenergieverbräuche werden im 4-Jahresmittel nach der Klimakorrekturen im besten Fall mit plus 6 Prozent und im schlechtesten Fall mit plus 13 Prozent überschätzt.

Validierung auf Stadtebene

Ein umfassender Vergleich der prognostizierten Blockbedarfe mit den Blockverbräuchen des Energieatlas Berlin wird sowohl auf der Prognoseseite als auch auf der Seite der Verbrauchserfassung mit einer Reihe Unsicherheiten erschwert.

Die energetischen Sanierungszustände der Einzelgebäude, welche in die Blockprognosen eingehen, wurden plausibel algorithmisch geschätzt über Parameter wie z.B. das Gebäudealter, der Gebäudetyp, die Gebäudenutzung oder ein gegebenenfalls vorliegender Denkmalschutz. Diese Datengrundlage ist zurzeit für erhebliche Teile des Berliner Gebäudebestands, vor allem im Bereich der Nichtwohngebäude, noch mit größeren Unsicherheiten behaftet.

Die im Energieatlas Berlin veröffentlichten Blockverbräuche umfassen nur die jährlichen Erdgas- und Fernwärme-Verbräuche, andere Energieträger wie Heizöl oder Strom für Wärmepumpen werden nicht erfasst (laut einer Studie des bdew (bdew, 2024) wurden 2023 ca. 87 Prozent aller Berliner Wohnungen mit Erdgas oder Fernwärme beheizt).

Gleichwohl lässt sich feststellen, dass das KI-Prognosemodell von EnergyMap Berlin im Mittel plausible Bedarfswerte berechnet, was durch die Lage des Maximums (Verhältnis KI-Prognose zu Verbrauch im Bereich 0,95 – 1,025) verdeutlicht wird.

Zusammenfassung

Grundlegend lässt sich feststellen, dass das KI-Prognosemodell von EnergyMap Berlin plausible

Jahresheizenergiebedarfe sowohl auf Ebene des Einzelgebäudes als auch der Gebäudeblöcke berechnen kann. Die Berücksichtigung eines Klimakorrektureffektors, welcher den Wärme-Inseleffekt im Berliner Stadtzentrum, berücksichtigt, kann die Prognosegüte auf Ebene des Einzelgebäudes noch einmal erheblich verbessern, ebenso das Nutzen von Zusatzwissen über das Einzelgebäude zur Präzisierung der Eingabewerte in das KI-Prognosemodell.

Das KI-Prognosemodell von EnergyMap Berlin wird in den nächsten Jahren in den Forschungsverbundprojekten CO2OL ISLANDS (<https://co2ol-islands.de>) und CoolingMap (<https://coolingmap.de>) stetig weiterentwickelt und wiederholt validiert werden. Hierzu gehören u.a. der Erweiterung der Rebound-Funktion auf Nichtwohngebäude, die Integration der lokalen Klimakorrektur in das Prognosemodell als auch eine systematische Überprüfung der statistischen Datenbasis (z.B. bzgl. der Gebäudetypenzuweisung oder angenommener Gebäudegeschossigkeiten).

Danksagung

Die vorgestellten Forschungsergebnisse basieren auf dem Projekt „EnEffWärme: EnergyMap Berlin - Online-Plattform zur Erstellung eines gebäudescharfen digitalen Wärmekatasters für den Gebäudebestand des Landes Berlin“ (Förderkennzeichen: 03EN3051A/B/C/D/E, gefördert vom BMWK).

Literatur

Dochev I., Muñoz Hidalgo M. E., Seller H., Peters I. 2018. Assigning energetic archetypes to a digital cadastre and 18 estimating building heat demand. An example from Hamburg, Germany. Hamburg: HafenCity University, Technical 19 Infrastructure Systems Group. Working Paper.

Wyrwa A., Chen Y. 2017. Mapping Urban Heat Demand with the Use of GIS-Based Tools. *Energies* 2017, 10, 720.

Moreno D., Nielsen S., Yuan M., & Dahl Nielsen F. 2024. The ODHeatMap Tool: Open Data District Heating Tool for Sustainable Energy Planning. *International Journal of Sustainable Energy Planning and Management*, 42, 48-71.

Yang X., Hu M., Heeren N., Zhang C., Verhagen T., Tukker A., Steubing B. 2020. A combined GIS-archetype approach to model residential space heating energy: A case study for the Netherlands including validation. *Applied Energy*. 280 (2020) 115953.

Calderón C., Cardenas M. A., Aoun J. 2024. Quantifying peak heat demand in neighbourhoods: A UBE approach and its implications for residential heating electrification in the UK - A case study of Newcastle upon Tyne. *Energy and Buildings*, Volume 321 (2024) 114609.

Wang C. K., Tindemans S., Miller C., Agugiaro G., Stoter J. 2020. Bayesian calibration at the urban scale: a case study on a large residential heating demand application in Amsterdam. *Journal of Building Performance Simulation*, 13(3), 347–361.

Schwanebeck M., Krüger M., Duttman R. 2021. Improving GIS-Based Heat Demand Modelling and Mapping for Residential Buildings with Census Data Sets at Regional and Sub-Regional Scales. *Energies* 2021, 14, 1029.

Segbers S., Küster-Inderfurth A., Nytsch-Geusen, C. 2024. Revolutionizing Heating Planning: A Data-Driven Approach for Accurate and Scalable Energy Consumption Predictions. *Proceedings BAUSIM 2024 Conference*, 23.-26. September, Wien.

Weiler V., Duminil E., Schröter B., Coors V., Brüggeman T., Balbach B., Goll L., Klöber A. 2021. Automatisierte Modellierung von Quartierswärmebedarfen auf Basis von 3D-Gebäudemodellen. *EuroHeat&Power* 4-5.2021.

Haas R., Biermayr P. 2000. The rebound effect for space heating: Empirical evidence from Austria, *Energy Policy*, 28(6-7), 403-410.

Guerra Santin O. 2013. Occupant behaviour in energy efficient dwellings: evidence of a rebound effect, *Journal of Housing and the Built Environment*, 28, 311–327.

Aydin E., Brounen D., Kok N. 2017. Energy efficiency and household behavior: the rebound effect in the residential sector, *The RAND Journal of Economics*, 48, 749-782.

Loga T. 2019. Berücksichtigung des Nutzerverhaltens bei energetischen Verbesserungen. *BBSR-Online-Publikation* Nr. 04/2019.

Deutscher Wetterdienst, 2026. HOSTRADA - Hochaufgelöster Stündlicher Rasterdatensatz. Open Data-Portal des DWD: https://opendata.dwd.de/climate_environment/CDC/grids_germany/hourly/hostrada/.

Bundesverband der Energie- und Wasserwirtschaft (bdew) e.V. 2024. „Wie heizt Berlin?“- Regionalbericht 2023 - Studie zum Heizungsmarkt Dezember 2024.