

BBSR-
Online-Publikation
22/2025

BaU-SaN

Anwendung von Bayes'scher Statistik zur Modellkalibrierung und Unsicherheitsanalyse von energetischer Sanierungsplanung in Nicht-Wohngebäude-Portfolios

von

Dr.-Ing. Rita Streblow
Katalin Fülep
Mary Lidiya Kalathiparambil Kennedy
Dr.-Ing. Stefan Brandt

BaU-SaN

Anwendung von Bayes'scher Statistik zur Modellkalibrierung
und Unsicherheitsanalyse von energetischer Sanierungsplanung
in Nicht-Wohngebäude-Portfolios

Gefördert durch:



Bundesministerium
für Wohnen, Stadtentwicklung
und Bauwesen

aufgrund eines Beschlusses
des Deutschen Bundestages

ZUKUNFT BAU
FORSCHUNGSFÖRDERUNG

Dieses Projekt wurde gefördert vom Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Auftrag des Bundesministeriums für Wohnen, Stadtentwicklung und Bauwesen (BMWSB) aus Mitteln des Innovationsprogramms Zukunft Bau.

Aktenzeichen: 10.08.18.7-21.37

Projektlaufzeit: 08.2021 bis 11.2024

IMPRESSUM

Herausgeber

Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR)
im Bundesamt für Bauwesen und Raumordnung (BBR)
Deichmanns Aue 31–37
53179 Bonn

Fachbetreuer

Bundesinstitut für Bau-, Stadt- und Raumforschung
Referat WB 3 „Forschung und Innovation im Bauwesen“
Andreas Windisch
andreas.windisch@bbr.bund.de

Autorinnen und Autoren

TU Berlin
Fachgebiet für digitale Vernetzung von Gebäuden, Energieversorgungsanlagen und Nutzenden
Dr.-Ing. Rita Streblow

Katalin Fülep
Mary Lidiya Kalathiparambil Kennedy

TU Berlin
Hermann-Rietschel-Institut
Dr.-Ing. Stefan Brandt
s.brandt@tu-berlin.de

Redaktion

TU Berlin

Stand

Dezember 2024

Gestaltung

TU Berlin

Bildnachweis

Titelbild: KI-generiert

Vervielfältigung

Alle Rechte vorbehalten

Der Herausgeber übernimmt keine Gewähr für die Richtigkeit, die Genauigkeit und Vollständigkeit der Angaben sowie für die Beachtung privater Rechte Dritter. Die geäußerten Ansichten und Meinungen müssen nicht mit denen des Herausgebers übereinstimmen.

Zitierweise

Streblow, R.; Fülep, K.; Kalathiparambil Kennedy, M. L.; Brandt, S., 2025: BaU-SaN: Anwendung von Bayes'scher Statistik zur Modellkalibrierung und Unsicherheitsanalyse von energetischer Sanierungsplanung in Nicht-Wohngebäude-Portfolios. BBSR-Online-Publikation 22/2025, Bonn. <https://doi.org/10.58007/04s8-k584>

DOI 10.58007/04s8-k584

ISSN 1868-0097

Bonn 2025

Inhalt

Abkürzungen	5
1 Kurzfassung.....	6
2 Summary	8
3 Einleitung	10
3.1 Motivation.....	10
3.2 Historische Daten für die Modellimplementierung und -validierung	11
3.3 Zugehörige Tools	11
4 Problemstellung.....	12
4.1 Herausforderungen bei der Kalibrierung von Energiemodellen	12
4.2 Wissenslücke.....	14
5 Zielsetzung	16
5.1 Umfang der Forschung und Zielsetzung:.....	16
6 Forschungsdesign	18
6.1 Hypothese	18
6.2 Vision	19
6.3 Potenzielle Nutzer und Zielgruppen.....	19
6.4 Projektteam und Organisation, Kooperationspartner	20
6.5 Arbeitspakete und Meilensteine	20
7 Verlauf des Projekts: Modell-Konzepte.....	21
7.1 Ziel 1	21
7.2 Ziel 2	22
7.3 Ziel 3	23
7.4 Ziel 4	27
7.5 Ziel 5	30
7.6 Ziel 6	33
7.7 Ziel 7	36
7.8 Zusammenfassung der Hauptziele	37
8 Ergebnisse	39
8.1 Fallstudie 1	39
8.1.1 Gebäudeenergiemodell	40
8.1.2 Sensitivitätsanalyse.....	41
8.1.3 Gaußsches Prozess-Surrogatmodell.....	43
8.1.4 Definition der prioritären Parameterverteilung.....	46
8.1.5 Modellkalibrierung	47

8.1.6 Kalibriertes Modell.....	52
8.1.7 Vorhersage-Szenario	54
8.2 Fallstudie 2.....	55
8.2.1 Gebäudeenergiemodell	55
8.2.2 Sensitivitätsanalyse.....	57
8.2.3 Gaußsches Prozess-Surrogatmodell.....	59
8.2.4 Definition der prioritären Parameterverteilung.....	63
8.2.5 Modellkalibrierung	64
8.2.6 Kalibriertes Modell.....	71
8.2.7 Qualität der Kalibrierung.....	75
8.3 Überblick.....	76
8.3 Open-Source-Repository.....	78
8.3.1 Datenanforderungen	78
8.3.2 Benutzereingaben	79
8.3.3 Back-End-Prozesse.....	80
9 Schlussfolgerung und Ausblick	85
Referenzen.....	88

Abkürzungen

AMY	Tatsächliches meteorologisches Jahr
BC	Bayes'sche Kalibrierung
BPS	Simulation der Gebäudeleistung
BIM	Berliner Immobilienmanagement GmbH
DIBS	Dynamic ISO Building Simulator
DWD	Deutscher Wetterdienst
FAST	Fourier-Amplituden-Sensitivitätstest
GA	Genetischer Algorithmus
THG	Treibhausgasemissionen
GP	Gauß-Prozess
GPR	Gaußsche Prozess Regression
LHS	Latin-Hypercube-Sampling
MCMC	Markov-Chain-Monte-Carlo
ML	Maschinelles Lernen
NRMSE	Normalisierter mittlerer quadratischer Fehler (Root Mean Squarred Error)
PCE	Polynomial Chaos Expansion
R^2	Bestimmtheitsmaß
RBF	Radiale Basisfunktionsnetzwerke
RDBMS	Relationales Datenbankmanagementsystem
SA	Sensitivitätsanalyse
SQL	Structured Query Language
TRY	Test Referenzjahr

1 Kurzfassung

In diesem Bericht wird ein fortschrittliches Bayes'sches Kalibrierungsframework beschrieben, das darauf abzielt, die Genauigkeit von Gebäudeenergiemodellen durch den Abgleich mit realen Messdaten zu verbessern, wobei inhärente Unsicherheiten bei Gebäudeeigenschaften, Gebäudeenergiemodellen und Messdaten berücksichtigt werden. Das Framework integriert statistische Bayes-Methoden, die Modellparameter iterativ auf der Grundlage von Beobachtungsdaten anpassen, was zu einem kalibrierten Gebäudeenergiemodell mit den damit verbundenen Unsicherheiten führt. Dies bietet ein zuverlässiges Werkzeug für die Entscheidungsfindung im Bereich der Energieeffizienz und der Kohlenstoffreduzierung im Gebäudesektor. Dieser Ansatz ist besonders wichtig, da auf Gebäude fast ein Drittel des weltweiten Energieverbrauchs und ein Viertel der energiebezogenen Emissionen entfallen und eine präzise Simulation der Gebäudeleistung (BPS) für die Ermittlung und Umsetzung von Energiesparmaßnahmen entscheidend ist.

Den Kern dieses Kalibrierungsframeworks bildet das Bayes'sche Theorem, das die Modellparameter verfeinert, indem es Vorwissen mit Messdaten kombiniert, um die Wahrscheinlichkeitsverteilung jedes Parameters iterativ zu aktualisieren. Das Bayes'sche Theorem eignet sich besonders gut für die Modellkalibrierung, da es sowohl die Parameterunsicherheiten als auch die Übereinstimmung der Parameter mit den beobachteten Daten quantifiziert. Im Kalibrierungsprozess aktualisiert das Bayes'sche Theorem die Wahrscheinlichkeitsverteilung eines Modellparameters auf der Grundlage früherer Informationen und erfasster Messdaten, wodurch eine informierte Posterior-Verteilung entsteht. Dies ermöglicht die Erstellung einer Wahrscheinlichkeitsverteilung von Parameterschätzungen, die eine genauere Simulation des Energiebedarfs eines Gebäudes darstellen.

Dieses Framework ist als Open-Source-Tool auf Python-Basis konzipiert, das die Bayes'sche Kalibrierung (BC) für Gebäudeenergiemodelle automatisiert. Es umfasst mehrere Schritte: Datenerfassung, Modellentwicklung, Sensitivitätsanalyse, Erstellung von Metamodellen, Bayes'sche Kalibrierung und Performance Bewertung. Das Endergebnis ist ein kalibriertes Gebäudeenergiemodell, das Wahrscheinlichkeitsverteilungen von Simulationsergebnissen ausgibt, die eine sichere Entscheidungsfindung über Sanierungsstrategien erleichtern.

In der ersten Phase werden umfassende Daten über das Gebäude gesammelt, einschließlich erster Schätzungen für die wichtigsten Parameter und die damit verbundenen Unsicherheiten. Für diese Studie wurde ein Datensatz von der BIM Berliner Immobilienmanagement GmbH genutzt, der als Grundlage für die Entwicklung und Bewertung des in dieser Untersuchung festgelegten Rahmens dient.

Anschließend wird ein Energiemodell des Gebäudes entwickelt, das einer Kalibrierung unterzogen wird. In diesem Projekt wurde der Dynamische ISO-Gebäudesimulator (DIBS) aufgrund seiner Recheneffizienz, der minimalen Anforderungen an die Eingangsparameter und der Kompatibilität mit deutschen Normen gewählt, was die Parametrisierung erleichtert und damit auch die Anwendbarkeit des Programms erweitert.

In der darauffolgenden Phase wird eine varianzbasierte Sensitivitätsanalyse durchgeführt, um die Parameter mit den größten Auswirkungen auf die Ergebnisse des Modells zu ermitteln, die Kalibrierung auf die einflussreichsten Parameter auszurichten und den Rechenaufwand zu verringern. Die Saltelli-Stichprobentechnik erzeugt eine Vielzahl von Parameterkombinationen, und die Sensitivität wird anhand des Sobol-Sensitivitätsindex bewertet. Parameter mit hoher Empfindlichkeit werden für die weitere Kalibrierung ausgewählt, um eine Überparametrisierung zu vermeiden und die Genauigkeit der Kalibrierung zu verbessern.

Anschließend wird ein auf Gauß'scher Regression basierendes Metamodell oder Ersatzmodell erstellt, um die Beziehung zwischen Eingaben und Ausgaben zu simulieren, ohne den Rechenaufwand des ursprünglichen Modells zu haben. Durch iteratives Training und Verfeinerung fungiert dieses Metamodell als Stellvertreter im Kalibrierungsprozess und verbessert die Recheneffizienz bei gleichbleibender Genauigkeit der Ergebnisse.

Als Nächstes folgt die eigentliche Kalibrierung, bei der die Bayes'sche Kalibrierung Priorverteilungen mit Likelihood-Funktionen kombiniert, die die Anpassung der beobachteten Daten an das Modell widerspiegeln. Dieser Prozess beinhaltet eine iterative Probenahme und Bewertung mit dem Markov-Chain-Monte-Carlo-Ansatz (MCMC), bei dem ein Satz von Parameterproben allmählich zu einer Verteilung konvergiert, die die Datenanpassung maximiert. Die Konvergenz wird mit Hilfe der Gelman-Rubin-Statistik bestimmt, um sicherzustellen, dass die Stichprobenvarianz innerhalb und zwischen den Ketten ausreichend ähnlich ist, um stabile Ergebnisse zu signalisieren.

Die aus der Kalibrierung resultierenden posterior Wahrscheinlichkeitsverteilungen definieren die endgültigen Parameterwerte für das Energiemodell. Im Gegensatz zu herkömmlichen Modellen liefert das kalibrierte Modell die Ergebnisse in Form einer Verteilung und nicht als einzelnes deterministisches Ergebnis und bietet so einen probabilistischen Ansatz für Sanierungssimulationen. Diese probabilistische Ausgabe enthält Konfidenzintervalle, die es dem Benutzer ermöglichen, die Wahrscheinlichkeit des Erreichens der angestrebten Energieeinsparungen vorherzusagen.

Das Modell wird validiert, indem seine kalibrierten Ergebnisse mit Messdaten verglichen werden, wobei Messgrößen wie das Bestimmtheitsmaß (R^2) und der Variationskoeffizient des mittleren quadratischen Fehlers (CV(RMSE)) zur Beurteilung der Genauigkeit verwendet werden. Diese Metriken bestätigen, dass das kalibrierte Modell gut auf unbekannte Daten verallgemeinert werden kann und eine robuste Leistung gewährleistet.

Zu den Forschungsergebnissen gehört ein Python-basiertes Framework, das unter folgendem [LINK](#) als Open-Source-Repository veröffentlicht wurde. Das Framework wurde so konzipiert, dass es anpassungsfähig ist und die unkomplizierte Integration neuer Gebäude ermöglicht, und die Kalibrierung verschiedener Gebäudeenergiemodelle erleichtert. Das DIBS-Gebäudeenergiemodell dient als primäres Modell in dieser Forschung, obwohl es, zusammen mit anderen Komponenten des Frameworks, vollständig austauschbar ist, wenn alternative Methoden oder Modelle gewünscht sind.

In diesem Bericht werden zwei Fallstudien vorgestellt, um die Anwendung und Wirksamkeit des Frameworks zu demonstrieren. Die erste Fallstudie konzentriert sich auf ein Gebäude aus der Datenbank der BIM Berliner Immobilienmanagement GmbH und zeigt die Leistung des Frameworks bei der Kalibrierung eines Modells mit Daten des Testreferenzjahres (TRY) und des tatsächlichen meteorologischen Jahres (AMY). Die zweite Fallstudie verwendet einen nachträglich gewonnenen Datensatz, der verschiedene zeitliche Auflösungen von Messdaten für ein einzelnes Gebäude enthält. Diese Fallstudie veranschaulicht die Fähigkeit des Frameworks, mit Daten unterschiedlicher zeitlicher Granularität zu kalibrieren, und gibt einen Einblick in die Leistung der Kalibrierung über mehrere Detailstufen in Zeitreihendaten.

2 Summary

This report outlines an advanced Bayesian calibration framework aimed at improving the accuracy of building energy models through alignment with real-world metered data, addressing inherent uncertainties in building characteristics, building energy modelling and measurement data. The framework integrates Bayesian statistical methods, which adjust model parameters iteratively based on observed data, resulting in a calibrated building energy model with associated uncertainties. This offers a reliable tool for decision-making in energy efficiency and carbon mitigation within the building sector. This approach is particularly relevant given that buildings account for nearly a third of global energy consumption and a quarter of energy-related emissions, and precise building performance simulation (BPS) is critical for identifying and implementing energy-saving measures.

At the core of this calibration framework lies Bayes' Theorem, which refines model parameters by combining prior knowledge with metered data to iteratively update the probability distribution of each parameter. Bayes' Theorem is particularly suited for model calibration as it quantifies both parameter uncertainties and how well parameters align with observed data. In the calibration process, Bayes' Theorem updates the probability distribution of a model parameter based on prior information and acquired metered data, producing an informed posterior distribution. This allows for the creation of a probability distribution of parameter estimates that represent a more accurate simulation of a building's energy performance.

This framework is designed as an open-source Python-based tool that automates Bayesian calibration for building energy models. It comprises several steps: data collection, model development, sensitivity analysis, meta-model creation, Bayesian calibration and performance evaluation. The final outcome is a calibrated building energy model that outputs probability distributions of simulation results, which facilitate confident decision-making about retrofit strategies.

The first stage involves collecting comprehensive data on the building, including initial estimates for key parameters and their associated uncertainties. For this study, a dataset was acquired from BIM Berliner Immobilienmanagement GmbH, serving as the foundation for developing and assessing the framework established in this research.

Next, an energy model of the building is developed to undergo calibration. In this project, the Dynamic ISO Building Simulator (DIBS) was chosen due to its computational efficiency, minimal input parameter requirements, and compatibility with German standards facilitating the parameterization, which in turn also broadens its applicability.

In the subsequent stage, a variance-based sensitivity analysis is conducted to identify the parameters with the highest impact on the model's output, guiding calibration toward the most influential parameters and reducing computational demands. The Saltelli sampling technique generates a diverse set of parameter combinations, and sensitivity is assessed using the Sobol Sensitivity Index. Parameters with high sensitivity are selected for further calibration, helping to avoid over-parameterization and improve calibration precision.

Next a Gaussian regression-based meta-model, or surrogate model, is created to simulate the relationship between inputs and outputs without the computational load of the original model. Through iterative training and refinement, this meta-model acts as a proxy in the calibration process, improving computational efficiency while preserving output accuracy.

Next follows the calibration itself, where the Bayesian calibration combines prior distributions with likelihood functions that reflect observed data's fit to the model. This process involves iterative sampling

and evaluation using the Markov Chain Monte Carlo (MCMC) approach, where a set of parameter samples gradually converges toward a distribution that maximizes data fit. Convergence is determined using Gelman-Rubin statistics, ensuring sample variance within and across chains is sufficiently similar to signal stable results.

The posterior probability distributions resulting from calibration define the final parameter values for the energy model. The calibrated model, unlike traditional models, provides output as a distribution rather than a single deterministic result, offering a probabilistic approach to retrofit simulations. This probabilistic output includes confidence intervals, allowing users to predict the likelihood of achieving targeted energy savings.

The model is validated by comparing its calibrated outputs to reserved metered data, using metrics such as Coefficient of Determination (R^2) and Coefficient of Variation of Root Mean Square Error (CV(RMSE)) to gauge accuracy. These metrics verify that the calibrated model generalizes well to unseen data, ensuring robust performance.

The research output includes a Python-based framework, released as an open-source repository under [LINK](#). Designed to be adaptable, the framework allows for straightforward integration of new buildings, facilitating the calibration of various building energy models. The DIBS building energy model serves as the primary model in this research, though it, along with other framework components, is fully interchangeable if alternative methods or models are desired.

This report presents two case studies to demonstrate the application and effectiveness of the framework. The first case study focuses on a building from the BIM Berliner Immobilienmanagement GmbH database, showing the framework's performance when calibrating a model using both Test Reference Year (TRY) and Actual Meteorological Year (AMY) data. The second case study uses a subsequently obtained dataset containing various time resolutions of metered data for a single building. This case study illustrates the framework's capability to calibrate using data with differing levels of temporal granularity, providing insight into the calibration's performance across multiple detail levels in time-series data.

3 Einleitung

3.1 Motivation

Da ein Drittel des weltweiten Energieverbrauchs und 25 % der CO₂-Emissionen auf Gebäude entfallen, spielen sie eine aktive Rolle beim Klimawandel (González-Torres et al., 2022). Trotz der dringenden Notwendigkeit, den Klimawandel abzuwenden, steigen der weltweite Energieverbrauch und die damit verbundenen CO₂-Emissionen in den letzten Jahren weiter an (Santamouris und Vasilakopoulou, 2021). Dieses Paradoxon unterstreicht die komplexe Herausforderung, ein harmonisches System zu schaffen, das wirtschaftliche Entwicklung, Energiebedarf und ökologische Nachhaltigkeit in Einklang bringt. Gebäudeenergiemodelle sind von größter Bedeutung für die Optimierung von Gebäudeenergiesystemen, die Identifizierung und Diagnose von Anomalien und Fehlern sowie die Entwicklung von Sanierungsstrategien zur Verbesserung der Nachhaltigkeit sowohl bestehender als auch in Planung befindlicher Gebäude. Doch selbst nach einigen Jahrzehnten der Bemühungen um die Entwicklung von Gebäudeenergiesimulationen (BEM) zur Unterstützung der Planung und Nachrüstung energieeffizienter Gebäude können die bestehenden Modelle die dynamische und stochastische Natur von Gebäudeenergiesystemen immer noch nicht erfassen (Hillen et al., 2024). Dies führt zu Modellschätzungen und -vorhersagen, die stark von der Realität oder den tatsächlichen Messdaten abweichen, was den Nutzen des Modells für das Energiemanagement und die Politikgestaltung untergräbt. Einer der Hauptgründe für diese Diskrepanz ist die inhärente Komplexität und Variabilität von Gebäudeenergiesystemen, die von zahlreichen Faktoren wie dem Nutzerverhalten, den Wetterbedingungen und dem Gebäudebetrieb beeinflusst werden. Diskrepanzen zwischen den Modellen ergeben sich auch aus dem Mangel an qualitativ hochwertigen, offenen und detaillierten Daten über Gebäude und deren Energieverbrauch, um mathematische Modelle auf der Grundlage der beobachteten Muster und Trends zu erstellen.

In Anbetracht der zunehmenden Bedeutung der Energieeffizienz und der Rolle von Gebäudeenergiesimulationen bei der Unterstützung des Gebäudesektors bei der Erreichung der Klimaziele sollte die Simulation des thermischen Gebäudeverhaltens in der Lage sein, reale Szenarien zu repräsentieren, das komplexe Verhalten des Gebäudes anzunähern und sich eng an die tatsächlichen physikalischen Eigenschaften und den Betrieb des Gebäudes anzupassen. Um ein Modell zu entwickeln, mit dem dieses Ziel erreicht werden kann, müssen die Parameter des Simulationsmodells kalibriert werden, damit zuverlässige Vorhersagen über das energetische Verhalten gemacht werden können. Nur genaue Vorhersagen können zu Kosteneinsparungen führen und das Vertrauen in die Einführung innovativer, umweltverträglicher Lösungen stärken. Kurz gesagt, die Kalibrierung der Eingangsparameter für die energetische Gebäudesimulation ist unerlässlich, um die Genauigkeit und Zuverlässigkeit der Vorhersagen des Energiebedarfs zu gewährleisten, ein effektives Energiemanagement zu ermöglichen, neue Technologien zu validieren, die Auswirkungen der Parameter zu verstehen und die Einhaltung von Vorschriften zu gewährleisten. All diese Faktoren tragen zur Entwicklung energieeffizienter Gebäude und zum Erreichen von Nachhaltigkeitszielen bei.

Allerdings erfordern die traditionellen Kalibrierungsmethoden große Mengen an historischen Daten über den Energieverbrauch und Gebäudedaten, was wiederum umfassende Prüfungen und Expertenurteile für nicht beobachtbare und unsichere Parameter erforderlich macht. Diese Methoden sind jedoch rechenintensiv und hängen in hohem Maße von umfangreichen Datenerhebungen und Expertenwissen ab, was sie ineffizient macht (Riddle et al., 2014). Darüber hinaus sind diese Methoden subjektiv, und die gewählten Parameterkombinationen repräsentieren möglicherweise nicht genau die wahren Eigenschaften des Gebäudes (Hong et al., 2018). Diese Unsicherheiten, die sich aus begrenzter Datenverfügbarkeit, Subjektivität und deterministischer Parameterschätzung ergeben, werden in den

kalibrierten Modellen nicht berücksichtigt. Infolgedessen stellen sie eine Herausforderung für Sanierungsentscheidungen dar, die sowohl finanzielle als auch CO₂-Minderungsstrategien betreffen.

Im Rahmen dieser Bemühungen wird ein verallgemeinerbarer Bayes'scher statistikgestützter Kalibrierungsansatz in einem kompletten Framework untersucht und implementiert, um die oben genannten Herausforderungen zu bewältigen. Dieser Ansatz gleicht nicht nur die Modellergebnisse mit den gemessenen Daten ab, sondern quantifiziert auch die inhärenten Unsicherheiten, die sowohl mit den Modellparametern als auch mit dem Modell selbst verbunden sind. Als Ergebnis dieses Prozesses entsteht ein kalibriertes Modell mit zugewiesenen Wahrscheinlichkeiten für seine Ergebnisse.

3.2 Historische Daten für die Modellimplementierung und -validierung

Diese Forschung wurde im Rahmen des Innovationsprogramms Zukunft Bau des Bundesministeriums für Wohnen, Stadtentwicklung und Bauwesen (BMWSB) durchgeführt, um die Forschung in der Bauwirtschaft zu unterstützen, wobei Klimaschutz, Energie- und Ressourceneffizienz und bezahlbares Bauen die Hauptschwerpunkte der Forschung sind, um eine nachhaltige Entwicklung des Bausektors zu fördern. Die BIM Berliner Immobilienmanagement GmbH als einer der passiven Partner stellte Daten für ihren Bestand von 978 Nichtwohngebäuden in Berlin zur Verfügung, die als Grundlage für die Entwicklung eines Frameworks für Gebäudeenergie-Simulationsmodelle dienen. Der Datensatz enthält umfassende Angaben zum Standort, zur Gebäudehülle, zu den technischen Anlagen und zur Nutzungsart der einzelnen Gebäude. Außerdem enthält er jährliche Daten zum gemessenen Wärmeenergieverbrauch von 2010 bis 2017. Von der Gesamtzahl der Gebäude in der Datenbank waren 183 Einzelgebäude mit gemessenen Energiedaten für jedes Gebäude separat verfügbar. Die übrigen Liegenschaften umfassten mehrere Gebäude, für die Messdaten für den gesamten Komplex zur Verfügung standen. Diese Aggregation von Daten erschwert die Analyse, da es schwierig ist, den Energieverbrauch einzelner Gebäude innerhalb dieser größeren Liegenschaften zu bestimmen. Dies erhöht die Komplexität des Simulationsprozesses und erschwert die Kalibrierung erheblich, da der Energieverbrauch der einzelnen Gebäude unbekannt ist. Daher wurden in diesem Projekt nur die 183 Einzelgebäude berücksichtigt. In diesem Bericht wird eine spezifische Fallstudie vorgestellt, um die Anwendbarkeit der implementierten Bayes'schen Kalibrierungsmethode (BC) zu demonstrieren.

3.3 Zugehörige Tools

Obwohl der in der aktuellen Studie implementierte Bayes'sche Framework für die Kalibrierung eines breiten Spektrums von Gebäudeenergie-Simulationswerkzeugen verwendet werden kann, wurde in der aktuellen Arbeit das DIBS (Dynamic ISO Building Simulator) Gebäudeenergiemodell verwendet (Bischof et al., 2022). DIBS ist ein rechnerisch effizientes Gebäudeenergiesimulationsprogramm, das speziell auf deutsche Nichtwohngebäude nach dem Gebäudeenergiegesetz zugeschnitten ist und die Abschätzung des Gesamtwärmeenergiebedarfs und des entsprechenden Treibhauspotenzials sowie die Berechnung des Wärmebedarfs für Raumheizung, Warmwasserbereitung, Kühlung und Strom ermöglicht. Der Simulator verwendet ein Widerstands-Kapazitäts-Modell, das auf der vereinfachten Stundenmethode nach ISO 13790:2008 basiert. Dieses auf Python basierende Modell ist ein benutzerfreundliches Simulationswerkzeug, das interoperabel ist und leicht für die Simulation und Validierung des implementierten Bayes'schen Frameworks für die Kalibrierung verwendet werden kann.

4 Problemstellung

4.1 Herausforderungen bei der Kalibrierung von Energiemodellen

Die Gebäudeenergiesimulation ist ein wertvolles Instrument zur Bewertung des Energiebedarfs eines Gebäudes und zur Evaluierung verschiedener Nachrüstungsmaßnahmen zur Optimierung energiesparender Verbesserungen. Sie spielt eine entscheidende Rolle bei der Ermittlung der wirksamsten energieeffizienten Maßnahmen, da der Energieverbrauch eines Gebäudes je nach seinen Merkmalen, wie der Gebäudehülle, den Außenwitterungsbedingungen, dem Verhalten der Bewohner, den installierten Technologien und Geräten, stark variieren kann (Al-Shargabi et al., 2022; Olu-Ajayi et al., 2024). In der Baubranche sind jedoch Bedenken hinsichtlich der Zuverlässigkeit der Modelle aufgekommen, da mit der weit verbreiteten Einführung intelligenter Energiezähler erhebliche Unterschiede zwischen dem simulierten und dem tatsächlichen Energieverbrauch deutlich werden (Chong et al., 2021). Bei der Simulation eines Gebäudes liegen häufig unzureichende oder ungenaue Informationen vor, die zu diesen Diskrepanzen führen. Faktoren wie das Verhalten der Bewohner (Gill et al., 2010), Klimadaten (Bhandari et al., 2012), Steuerungsstrategien (Bourgeois et al., 2006), Unsicherheiten bei Entwurfsparametern und Materialeigenschaften (Hopfe et al., 2011) tragen zu dieser Diskrepanz bei. Die Studie Energy Performance of LEED for New Construction Buildings (Energieleistung von LEED-Neubauten), in der 121 Gebäude analysiert wurden, hat beispielsweise gezeigt, dass die Prognosen des energetischen Gebäudemodells erheblich abweichen können und zwischen dem 0,36- und 2-fachen des tatsächlich gemessenen Energieverbrauchs liegen (New Buildings Institute, 2008). Die Kalibrierung des Gebäudeenergiemodells ist daher von entscheidender Bedeutung, um die tatsächlichen Eigenschaften des Gebäudes und sein Verhalten als Energiesystem genau zu bestimmen, was zuverlässigere Vorhersagen über die Auswirkungen von Energieeffizienzstrategien ermöglicht.

In ihrer Übersichtsarbeit "A Review of Methods to Match Building Energy Simulation Models to Measured Data" fassen Coakley et al. (2014) die wichtigsten Herausforderungen bei der Simulation mit kalibrierten Gebäudeenergiemodellen zusammen, darunter:

- **Identifizierung:** Die Kalibrierung ist zumeist ein Ad-hoc-Prozess, der mehrere manuelle Anpassungen auf der Grundlage von Expertenurteilen und nicht von standardisierten, evidenzbasierten Methoden umfasst. Einige Studien bieten zwar Leitlinien für die Behandlung von Kalibrierungsproblemen, aber ein klares, einheitliches Verfahren fehlt nach wie vor.
- **Automatisierung:** Die Automatisierung würde den Kalibrierungsprozess erheblich verbessern, da weniger manuelle Eingriffe erforderlich wären. Die Umsetzung ist jedoch eine Herausforderung, da viele Schritte immer noch menschliches Fachwissen und Urteilsvermögen erfordern.
- **Vereinfachung:** Detaillierte Gebäudeenergiesimulationen erfordern Tausende von Eingaben, von denen sich viele nicht genau messen lassen oder unpraktisch sind.
- **Eingaben:** In jeder Modellierungsumgebung hängt die Qualität der Ergebnisse direkt von der Qualität der Eingaben ab. Aufgrund der begrenzten Verfügbarkeit von Daten erfordert die Aufrechterhaltung der Modellqualität genaue Annäherungen der Eingaben, um eine Beeinträchtigung der Zuverlässigkeit der Ergebnisse zu vermeiden.
- **Ungewissheit:** Da die Gebäudeenergiemodellierung auf Annäherung und Vereinfachung beruht, ist es wichtig, diese Unsicherheiten in den Modellergebnissen zu berücksichtigen. Eine Hauptquelle der Ungewissheit ist die Spezifikation der Parameter, der es oft an Präzision

mangelt, was zu potenziellen Ungenauigkeiten in den Modellergebnissen führt - ein Problem, das in Studien zur Kalibrierung von Gebäudeenergiemodellen häufig übersehen wird.

- Kosten: Das Fehlen von standardisierten Werkzeugen und Datenformaten treibt die Kosten für die Modellentwicklung und -kalibrierung in die Höhe. Ohne eine einheitliche Toolchain und mit begrenzten Daten zu vielen notwendigen Gebäudeparametern bleiben die Aufwände für die Prüfung, Messung und Modellentwicklung erheblich.
- Normen: Das Fehlen eines standardisierten Ansatzes für die Modellkalibrierung ist nach wie vor eine große Herausforderung bei der Energiemodellierung.

In der Studie "Methodologies and Advancements in the Calibration of Building Energy Models" (Methoden und Fortschritte bei der Kalibrierung von Gebäudeenergiemodellen) werden die am häufigsten verwendeten Kalibrierungsmethoden untersucht (Fabrizio et al., 2015). Wie beschrieben, kann die Kalibrierung auf zwei Arten erfolgen: manuell, mit einer iterativen, praktischen Anpassung durch den Modellierer, oder automatisch, wobei der Prozess durch ein automatisiertes System ohne direkten Benutzereingriff gesteuert wird.

Manuelle Kalibrierungsmethoden sind rechenintensiv und hängen in hohem Maße von einer umfangreichen Datenerfassung und Expertenwissen ab, was sie ineffizient macht (Riddle & Muehleisen, 2014). Darüber hinaus sind diese Methoden subjektiv, und die gewählten Parameterkombinationen repräsentieren möglicherweise nicht genau die wahren Eigenschaften des Gebäudes (Hong et al., 2018). Diese Unsicherheiten, die sich aus der begrenzten Datenverfügbarkeit, der Subjektivität und der deterministischen Parameterschätzung ergeben, werden in den kalibrierten Modellen nicht berücksichtigt, was die Probleme der Kosten, der Vereinfachung und der Unsicherheit deutlich macht.

Automatisierte Kalibrierungsmethoden verringern zwar den Einfluss der Subjektivität des Modellierers und erfordern im Allgemeinen weniger Zeit als manuelle Methoden, sind aber dennoch mit Unsicherheiten behaftet. Diese Unsicherheiten können in drei Kategorien eingeteilt werden, die von Chong et al. (2021) in ihrem Übersichtsartikel definiert wurden:

- 1) Parameter-Unsicherheit: Diese ergibt sich aus einflussreichen Modellinputs, die nicht genau bekannt sind.
- 2) Unsicherheit der Modellform: Diese resultiert aus Diskrepanzen zwischen dem Modell und dem realen System, die oft auf Annahmen, Abstraktionen und Annäherungen im Modell zurückzuführen sind.
- 3) Unsicherheit der Beobachtung: Dies hängt mit Fehlern in den für die Modellkalibrierung verwendeten Daten zusammen.

Interessanterweise berücksichtigen zwei Drittel der in der gleichen Studie untersuchten Studien die Unsicherheit während des Kalibrierungsprozesses nicht. Es gibt zwei Hauptansätze zur Quantifizierung der Unsicherheit: Vorwärts- und Umkehrmethoden.

- Bei Vorwärtsansätzen werden Unsicherheiten in den Modellparametern auf den Output übertragen, wobei in der Regel Stichprobenverfahren verwendet werden, um die Auswirkungen der vordefinierten Parameterunsicherheiten zu berücksichtigen.
- Inverse Ansätze zielen darauf ab, Unsicherheiten zu quantifizieren, indem Modellvorhersagen mit beobachteten Daten aus dem Gebäudesystem verglichen werden, wobei alle drei Arten von Unsicherheiten berücksichtigt werden.

Bayes'sche statistische Ansätze sind besonders effektiv für die Kalibrierung mit inversen Methoden, da sie von Natur aus Unsicherheiten im Zusammenhang mit Parametern, Modelldiskrepanzen und Beobachtungsfehlern einbeziehen. Durch die Anwendung von Bayes'schen Methoden auf die Kalibrierung von Gebäudeenergiemodellen ist es möglich, die Abweichungen zwischen simulierten und gemessenen Daten zu verringern, was zu zuverlässigeren Modellen führt. Dieser Ansatz geht direkt auf das Problem der Unsicherheit ein und ermöglicht es, diese zu quantifizieren und im Kalibrierungsprozess systematisch zu berücksichtigen, wie bereits erwähnt. Darüber hinaus können Bayes'sche Methoden automatisiert angewendet werden, wodurch die Notwendigkeit von Benutzereingaben minimiert und die Herausforderung der Automatisierung angegangen wird. Da der Kalibrierungsprozess Wahrscheinlichkeitsverteilungen verwendet, ist außerdem keine genaue Kenntnis bestimmter Parameterwerte erforderlich, wodurch das Problem der Identifizierung gelöst wird.

4.2 Wissenslücke

In den letzten Jahren hat sich die Bayessche Statistik bei der Modellkalibrierung zunehmend durchgesetzt (Chong & Menberg, 2018; Heo et al., 2012). Die meisten Studien in diesem Bereich haben Daten aus kontrollierten Umgebungstests verwendet (Calama-González et al., 2021; Heo et al., 2012; Monari & Strachan, 2017), aber um die Anwendbarkeit der Bayes'schen Kalibrierung effektiver zu demonstrieren, ist es wichtig, sie an einer größeren und vielfältigeren Anzahl von Gebäuden in realen Messszenarien zu testen, ohne die Bewohner zu stören. Um die Reproduzierbarkeit zu gewährleisten, sollte der Kalibrierungsprozess außerdem in der Lage sein, verschiedene zeitliche Auflösungen zu handhaben - etwa stündlich, monatlich oder jährlich - und damit seine Relevanz auf ein breiteres Spektrum von Gebäudetypen und Messbedingungen auszudehnen und zu besseren Standards in der Kalibrierungspraxis beizutragen.

Trotz zahlreicher Projekte zur Bayes-Kalibrierung haben die Komplexität der zugrundeliegenden Mathematik und das Fehlen eines verallgemeinerten, flexiblen Open-Source-Frameworks ihre breitere Anwendung eingeschränkt (Hou et al., 2021). Tabelle 1-A bis E im Anhang gibt einen Überblick über einen Teil der gesammelten Literatur und hebt verschiedene Modelle, Fallstudien, Ansätze und Techniken hervor. Dieser Überblick verdeutlicht die breite Anwendung dieser Methoden und Instrumente und unterstreicht gleichzeitig die Notwendigkeit eines allgemeinen Frameworks, der verschiedene Arten von Fallstudiengebäuden und Daten aufnehmen kann und die Reproduzierbarkeit erleichtert. Dieser Bedarf deckt sich mit den zuvor identifizierten Herausforderungen der Automatisierung und Standardisierung, da ein gut konzipiertes Werkzeug die erforderlichen manuellen Eingaben minimieren könnte, was den Prozess effizienter und weniger anfällig für die Subjektivität der Benutzer macht.

Die Komplexität der derzeitigen Kalibrierungsmethoden für Gebäudeenergiemodelle erschwert die Reproduzierbarkeit zusätzlich, wie in der jüngsten Übersichtsarbeit (Chong et al., 2021) hervorgehoben wird. Ohne Zugang zu den zugrundeliegenden Codes und Daten ist es nahezu unmöglich, die Grundprinzipien der wissenschaftlichen Forschung wie Transparenz, Genauigkeit und unabhängige Überprüfung einzuhalten. Die Überprüfung deutet auf einen erheblichen Mangel an Reproduzierbarkeit hin, der auf eine unzureichende Klarheit bei der Angabe von Modellierungsannahmen, Kalibrierungsparametern und beobachteten Inputs und Outputs zurückzuführen ist. Coakley et al. (2014) kamen nach einer Überprüfung bestehender Kalibrierungsverfahren zu dem Schluss, dass die Autoren, wenn ein Modell als kalibriert ausgewiesen wird, die verwendeten Verfahren oft nicht offenlegen und nur die endgültigen Kalibrierungsergebnisse angeben.

Um dieses Problem anzugehen, wird in der aktuellen Studie ein schrittweiser Ansatz zur Verbesserung der Reproduzierbarkeit in der Gebäudesimulationsforschung vorgeschlagen, einschließlich eines

vollständig reproduzierbaren Beispiels, das auf GitHub [LINK](#) als Open-Source-Repository bereitgestellt wird. Für eine breitere Zugänglichkeit sollte das Kalibrierungsframework so gestaltet sein, dass er auch von Personen ohne fortgeschrittene mathematische Fachkenntnisse, einschließlich Entscheidungsträgern, genutzt werden kann. Durch die klare Darstellung der wesentlichen Schritte für eine effektive Kalibrierung und die Automatisierung des Prozesses kann dieses Framework den Bedarf an tiefgreifenden Kenntnissen in Bayes'scher Statistik oder Gebäudeenergiemodellierung verringern und so eine breitere Anwendung mit minimalen Benutzereingriffen fördern und die zuvor identifizierten Herausforderungen der Kosten, Automatisierung und Identifizierung angehen.

5 Zielsetzung

5.1 Umfang der Forschung und Zielsetzung:

- 1) Durchführung einer umfassenden Literaturrecherche zu bestehenden Kalibrierungsmethoden, Bayes'scher Inferenz-gestützter Kalibrierung und Gebäude-Energiesimulationsmodellen mit dem Ziel, deren **Wirksamkeit bei der Kalibrierung** und **Interoperabilität mit anderen Tools** bzw. Frameworks zu bewerten.
- 2) Definition der notwendigen Daten für die Ausführung des implementierten Bayes'schen Kalibrierungsframeworks.
- 3) Auswahl eines geeigneten und interoperablen Gebäudeenergiemodells zur Bewertung der Robustheit und Effizienz des implementierten Bayes'schen Kalibrierungsframeworks.
- 4) Einrichtung eines optionalen Sensitivitätsanalyse-Tools innerhalb des Frameworks, um den Parameterraum der Simulationseingabeparameter zu analysieren und die empfindlichsten Parameter für die anschließende Kalibrierung zu ermitteln.
- 5) Erstellung eines auf einem Gaußschen Prozess basierenden Metamodells als Ersatzmodell für den ursprünglichen Energiebedarfssimulator, da die ursprünglichen Simulationsmodelle oft rechenintensiv sind.
- 6) Einrichtung eines Bayes'schen Inferenz-gestützten Kalibrierungswerkzeugs innerhalb der Werkzeugkette, das eine wirksame Feinabstimmung der Eingangsparameter des untersuchten Simulationsmodells ermöglicht, um eine Posterior-Wahrscheinlichkeitsverteilung zu erstellen, die als Input für das ursprüngliche Simulationsmodell dient, der das kalibrierte Modell darstellt.
- 7) Implementierung eines Bayesian Inference Integrated Calibration Frameworks für die Kalibrierung von Gebäudeenergiemodellen in Python und Bewertung, ob das implementierte Framework in der Lage ist, die Kalibrierung von Gebäudeenergiemodellen zu unterstützen, indem die in der ASHRAE-Richtlinie 14 festgelegte Kalibrierungsfehlerschwellen bewertet werden.
- 8) Validierung des implementierten Frameworks an einer Reihe von Fallstudiengebäuden aus der vom passiven Partner *BIM Berliner Immobilienmanagement GmbH* zur Verfügung gestellten Datenbank.
- 9) Quantifizierung der Unsicherheiten im Zusammenhang mit dem kalibrierten Modell und der Feinabstimmung der Modellinputparameter, um die finanzielle Bewertung und die Quantifizierung der umfassenderen Umweltauswirkungen der Energieeinsparungen von Gebäudesanierungsprojekten weiter zu unterstützen, da das kalibrierte Modell als Grundlage für datengestützte Entscheidungen und politische Entscheidungen über Energiesanierungsprojekte dient.
- 10) Simulation und Erstellung von Vorhersageszenarien zur Bewertung der Auswirkungen verschiedener Nachrüstungsmaßnahmen, um das potenzielle Erderwärmungspotenzial und die Kosteneinsparungen zu quantifizieren und zu verstehen, die sich aus den verschiedenen zugewiesenen Nachrüstungsmaßnahmen ergeben.
- 11) Geeignete Empfehlungen für die Nachrüstung von Gebäuden zur Senkung der Kosten und des GWP auf der Grundlage der vorausschauenden Szenariostudie zu geben.

- 12) Ermittlung der optimalen Intervalle, in denen die Daten für eine optimale Bewertung der Energieeffizienz und des Energiemanagements von Gebäuden erhoben werden sollten, sowie Ermittlung der optimalen Mindestdaten in Bezug auf die zeitliche Auflösung, den Zeitraum und die für eine gute Kalibrierung erforderlichen Merkmale.
- 13) Die Veröffentlichung des implementierten benutzerfreundlichen Frameworks als Open-Source-Tool.
- 14) Veröffentlichung eines Jupyter-Notizbuchs mit einem vereinfachten Anwendungsfall, der alle oben genannten Tools - Energiesimulationsmodell, Sensitivitätsanalyse, Metamodell und Bayes'sche Kalibrierung - umfasst, um die Verwendung der Bayes'schen Kalibrierung von Gebäudeenergiemodellen für Ausbildungszwecke einfach zu demonstrieren.

Die Bedeutung präziser Simulationen des energetischen Gebäudeverhaltens bei der Bewertung von Energieeinsparungen durch verschiedene Sanierungsmaßnahmen wird durch die Ergebnisse der vorliegenden Studie noch unterstrichen. Darüber hinaus unterstreicht diese Studie die entscheidende Rolle, die genaue Simulationen bei der Abschätzung der Wirksamkeit verschiedener Sanierungsstrategien zur Energieeinsparung spielen. Die genaue Kalibrierung von Gebäudeenergiemodellen ist von entscheidender Bedeutung, da die Simulation die physikalischen Eigenschaften des Gebäudes und die realen Betriebsszenarien widerspiegeln muss, um Energieeinsparungen korrekt vorherzusagen. Traditionelle Kalibrierungsmethoden sind arbeitsintensiv und erfordern Expertenwissen, was den Bedarf an effizienteren Ansätzen verdeutlicht. Außerdem geben diese Modelle oft keine Auskunft über ihre Genauigkeit. Die Bayes'sche Kalibrierung identifiziert nicht nur die unbekannten Parameter, sondern quantifiziert als statistikbasierte Methode auch die Unsicherheiten in den Modellen (Heo et al. 2012; Sokol et al. 2017; Chong und Menberg 2018). Dieser Ansatz bietet wertvolle Einblicke in die Wahrscheinlichkeit künftiger Energieeinsparungen und damit eine zuverlässigere Grundlage für Investitionsentscheidungen.

Ziel dieser Forschung ist die Entwicklung, Validierung und Optimierung eines auf Bayes'scher Inferenz basierenden Kalibrierungsframeworks für Gebäudeenergiemodelle. Dieses Framework soll die Schätzung der Gebäude-Eingangparameter verbessern, so dass der simulierte Energiebedarf eng mit den tatsächlich gemessenen Gebäudedaten übereinstimmt und so die Entwicklung genauer Gebäudeenergie-Simulationsmodelle unterstützt. Gleichzeitig kann durch die Anwendung der Bayes'schen Statistik auf den Kalibrierungsprozess die Unsicherheit des Modellergebnisses geschätzt werden, was die Simulation verschiedener Nachrüstungsmaßnahmen ermöglicht, die wiederum einen Anstoß für die Schätzung potenzieller Energieeinsparungen geben, die sich aus den neu geplanten Maßnahmen und der mit den Modellergebnissen verbundenen Unsicherheit ergeben. Ein solcher Rahmen kann den Entscheidungsträgern als solide Grundlage für die Bewertung von Energieeinsparstrategien dienen.

6 Forschungsdesign

6.1 Hypothese

- Die Bayes'sche Inferenz, die während des Kalibrierungsprozesses angewendet wird, ermöglicht die Schätzung unsicherer Eingangsparameter in einem Gebäudeenergiemodell.
- Die Sensitivitätsanalyse (SA), insbesondere unter Verwendung von Sobol-Indizes, kann bei einem gut abgetasteten Parameterraum ein leistungsfähiges Instrument zur Quantifizierung des Beitrags der einzelnen Eingangsparameter zur Ausgangsvariabilität des Modells sein. Darüber hinaus bietet das Modell ein umfassendes Verständnis der Interaktion von Parametern und ihrer relativen Bedeutung, was für die Modellkalibrierung entscheidend ist. Dieses Verständnis kann die Formulierung von Prioriverteilungen in der Bayes'schen Kalibrierung leiten, was zu einer fundierteren und effektiveren Kalibrierung führt. Die Identifizierung von Schlüsselparametern mit Hilfe der Sensitivitätsanalyse kann den Bayes'schen Kalibrierungsprozess weiter rationalisieren und möglicherweise die Dimensionalität des Parameterraums reduzieren. Dieser gezielte Ansatz steigert nicht nur die Effizienz der Berechnungen, sondern verbessert auch die Robustheit der Kalibrierung, indem er sicherstellt, dass nur die wichtigsten Parameter genau geschätzt werden. Zusammenfassend lässt sich sagen, dass die Durchführung einer SA für den Parameterraum der Modelleingaben in der Vor-Kalibrierungsphase die Kalibrierung verbessert, indem sie die Schlüsselparameter identifiziert, den Rechenaufwand reduziert und das Verständnis der Wechselwirkungen zwischen den Parametern verbessert, was letztlich zu zuverlässigeren und effizienteren Modellkalibrierungsprozessen führt.
- Gauß-Prozesse (GP) können das ursprüngliche Gebäudeenergiemodell effektiv approximieren und stellen ein rechnerisch effizientes Surrogat dar, das eine hohe Genauigkeit aufweist, wenn es anhand der Qualitätskennzahlen wie Bestimmtheitsmaß (R^2) und Normalized Root Mean Squared Error (NRMSE) gut an die Ergebnisse des ursprünglichen Modells angepasst ist. Die probabilistische Natur der Gaußschen Prozesse verbessert den Bayes'schen Kalibrierungsprozess, indem sie ein quantifizierbares Maß für die Unsicherheit der Modellvorhersagen liefert. Wenn Gauß-Prozesse als Ersatzmodell gut trainiert sind, reduzieren sie die Rechenkapazitäten erheblich, während sie die für eine effektive Bayes-Kalibrierung erforderliche Genauigkeit beibehalten. Zusammenfassend lässt sich sagen, dass Gauß-Prozesse als wirksame Ersatzmodelle für Gebäudeenergiesimulationen dienen, indem sie genaue, rechnerisch effiziente Näherungen mit inhärenter Unsicherheitsquantifizierung liefern und dadurch die Bayes'sche Kalibrierung von Modelleingangsparametern verbessern.
- Die Einbeziehung von Bayes'schen Statistiken mit Sensitivitätsanalysen und Gauß'schen Prozess-Metamodellen verbessert die Genauigkeit und Zuverlässigkeit der Kalibrierung von Gebäudeenergiemodellen, indem sie die Unsicherheit der Modellvorhersagen effektiv quantifiziert und reduziert.
- Die Bayes'sche Kalibrierung kann das Energiemodell eines Gebäudes effektiv verbessern, indem sie die Quantifizierung von Unsicherheiten bei der Modellvorhersage und die Integration von in der Literatur gut untermauertem Vorwissen ermöglicht und so wertvolle Erkenntnisse für die Optimierung der Gebäudeenergieeffizienz liefert.
- Die Bayes'sche Kalibrierung kann, wenn sie auf Modelle für die Gesamtenergieeffizienz von Gebäuden angewandt wird, mit dem Schwerpunkt auf Energie- und Umweltauswirkungsmetriken, zuverlässige Vorhersagen für Sanierungsmaßnahmen liefern und

so letztendlich zur Energieeffizienz und zu nachhaltigen Zielen beitragen. Dieser Ansatz nutzt die Stärken der Bayes'schen Methoden bei der Abschätzung von Unsicherheiten und bei der Entscheidungsfindung, wie die Forschungsergebnisse in den verschiedenen bereitgestellten Kontexten zeigen.

6.2 Vision

In diesem Abschnitt wird die Vision des Bayes'schen inferenzgestützten Kalibrierungsansatzes für Gebäudeenergiemodelle vorgestellt. Ein Überblick über das implementierte Modell findet sich im folgenden Kapitel 7. Eine Vision für diese Initiative ist die Verbesserung des Zugangs, der Produktivität und der Flexibilität auf der Grundlage der in der jüngsten Vergangenheit gewonnenen Erkenntnisse und die Entwicklung eines benutzerfreundlichen Bayes'schen Kalibrierungswerkzeugs. Erstens sollte das Tool darauf abzielen, die Unsicherheiten in der Gebäudeenergiemodellierung durch die Anwendung der Bayes'schen Inferenz als statistische Kalibrierungstechnik zu überwinden, um den Modellierungsprozess zu stärken (Hou et al., 2023, 2021). Damit soll die Kalibrierung automatisiert werden, ohne dass der Benutzer bei der Parameterauswahl viel Kontrolle hat und auf Expertenwissen angewiesen ist. Zur Verbesserung der Recheneffizienz könnte das Tool Ansätze wie die Surrogatmodellierung verwenden, die neuronale Netze oder parametrische Modelle umfassen könnte, die als Metamodell für komplexe Gebäudeenergiemodelle dienen könnten, die für die Analyse benötigt werden. Eine solche Einstellung kann, wie in aktuellen Arbeiten gezeigt wurde, dazu beitragen, die Rechenkosten für die Bayes'sche Kalibrierung um zwei oder mehr Größenordnungen zu reduzieren (Cant und Evins, 2023; Shen et al., 2023). Darüber hinaus sollte das Werkzeug in der Lage sein, umfassende Daten in verschiedenen zeitlichen Auflösungen zu verarbeiten, um detaillierte Analysen der Gebäudeleistung zu erstellen. Diese Fähigkeit ist besonders wichtig für die Entscheidungsfindung bei Nachrüstungen und die Energieoptimierung, die zu einer datengestützten Entscheidungsfindung mit Quantifizierung von Unsicherheiten führt, die zu Kosteneinsparungen und einer potenziellen Verringerung der Auswirkungen auf die globale Erwärmung beitragen (Shen et al., 2023). Alles in allem sollte die Vision dieses Tools die eines robusten, effizienten, leicht anpassbaren und benutzerfreundlichen Tools sein, das die von den Gebäuden erhaltenen Informationen integrieren und die Bayes'sche Inferenz einsetzen kann, um die Kalibrierungen der Energiemodelle für Gebäude zu verbessern. Durch die Förderung einer Open-Source-Gemeinschaft kann das Tool weiterentwickelt werden, um den unterschiedlichen Nutzerbedürfnissen gerecht zu werden und zu einer breiteren Akzeptanz von Bayes'schen Methoden in der Gebäudeenergiemodellierung beizutragen und so die datengestützte Entscheidungsfindung zu verbessern, um die Kosten und das globale Erwärmungspotenzial zu reduzieren, die sich aus dem Gebäudeenergiebereich ergeben.

6.3 Potenzielle Nutzer und Zielgruppen

Der Bayes'sche Kalibrierungsansatz richtet sich an ein Publikum, das sich mit Energiemanagement, Gebäudemodellierung und frühzeitiger Nachrüstungsplanung befasst. Zu dieser Zielgruppe gehören Architekten, Energie- und Bauingenieure sowie Entscheidungsträger, die sich mit politischen Entscheidungen befassen. Darüber hinaus kann das Tool von Projektentwicklern und Behörden vor der Formulierung des Gebäudeentwurfs eingesetzt werden, um ein umfassendes Verständnis der möglichen Bereiche von Kosteneinsparungen und der Reduzierung des Treibhauspotenzials oder der gewünschten Leistungsindikatoren für ein geplantes Projekt zu erhalten. Dieses Instrument hilft den Akteuren, durch den Vergleich mehrerer voraussichtlicher Szenarien fundierte Entscheidungen zu treffen.

6.4 Projektteam und Organisation, Kooperationspartner

Das Projekt wurde an der TU Berlin vom Fachgebiet für Digitale Vernetzung von Gebäuden, Energieversorgungsanlagen und Nutzenden unter Leitung von Prof. Dr.-Ing. Rita Streblow und dem Hermann-Rietschel-Institut mit Dr.-Ing. Stefan Brandt als Projektleiter bearbeitet. Die Hauptprojektbearbeiterin war die wissenschaftliche Mitarbeiterin Katalin Fülep, M. Sc. zeitweise unterstützt durch die wissenschaftliche Mitarbeiterin Siling Chen, M. Sc. Des Weiteren war Mary Lidiya Kalathiparambil Kennedy als studentische Hilfskraft in dem Projekt tätig.

Für das Projekt standen Daten der BIM Berliner Immobilienmanagement GmbH zur Verfügung.

6.5 Arbeitspakete und Meilensteine

Auf Grund einer sehr schlechten Bewerberlage konnte die Projektstelle erst mit neun Monaten Verzögerung besetzt und mit der Bearbeitung begonnen werden. Die Arbeiten haben die ursprünglich geplanten Zeitaufwendungen benötigt, so dass die ursprüngliche Projektlaufzeit vom 16.08.2021 bis 15.03.2024 bis zum 30.11.2024 kostenneutral verlängert wurde.

Dem Projekt standen Datensätze der BIM Berliner Immobilienmanagement GmbH des Projektes DATES zur Verfügung. Die Datensätze wurden für dieses Projekt gesichtet, aufbereitet und in eine eigene Projektdatenbank überführt. Die Datensätze enthalten allerdings keine abgesicherten Daten zu den gebäudetechnischen Installationen. Zudem existieren lediglich Jahresenergieverbräuche für 8 Jahre. Die Datenlage war damit zu schlecht um die eigentlich geplanten Betrachtungen von Sanierungsfahrplänen zu vertiefen und weitergehende Gesamtportfoliobetrachtungen durchzuführen.

Es konnten letztlich für wenige einzelne Gebäude höher aufgelöste Daten beschafft werden, so dass der Fokus in den verbleibenden Arbeiten auf Sensitivitätsuntersuchungen und der Optimierung des Frameworks hinsichtlich der benötigten Rechenkapazitäten gelegt wurde.

Im Antrag war zudem Modelica eine mögliche Option für die Gebäudemodellierung. Im Vergleich unterschiedlicher Modellierungsansätze wurde sich letztlich aber im Projekt für den pythonbasierten DIBS - Dynamic ISO Building Simulator entschieden, so dass keine Kosten für eine kommerzielle Entwicklungsumgebung für Modelica angefallen sind.

Die Projektergebnisse wurden auf der SimBuild Konferenz (21. - 23.5.2024) und der uSIM2024 Konferenz (25.11.2024) vorgestellt und mit der Fachcommunity diskutiert.

Fülep, K.; Chen, S.; Brandt, S.; Streblow, R.: Advancing Building Energy Modeling: An Open-Source Bayesian Calibration Framework for Non-residential Buildings, SimBuild 2024

Fülep, K.; Kalathiparambil Kennedy, M. L.; Brandt, S.; Streblow, R.: An Open-Source Framework: Bayesian Building Energy Model Calibration with Uncertainty Quantification, uSIM2024

7 Verlauf des Projekts: Modell-Konzepte

In diesem Kapitel werden die vorläufigen Ergebnisse sowie die Modellkonzepte vorgestellt, die zur Erreichung der im vorangegangenen Kapitel genannten Ziele untersucht und angenommen wurden. Das vorliegende Kapitel veranschaulicht, wie jedes der im vorigen Kapitel genannten Ziele im Laufe des Projekts erreicht wurde.

7.1 Ziel 1

*Durchführung einer umfassenden Literaturrecherche zu bestehenden Kalibrierungsmethoden, Bayes'scher Inferenz-gestützter Kalibrierung und Gebäude-Energiesimulationsmodellen mit dem Ziel, deren **Wirksamkeit bei der Kalibrierung und Interoperabilität mit anderen Tools** bzw. Frameworks zu bewerten.*

Es gibt eine Vielzahl von Kalibrierungsmethoden für die Gebäudeenergiekalibrierung, einschließlich deterministischer Kalibrierungsmethoden, die sich grob in manuelle und automatische Kalibrierung einteilen lassen. Nach Chong et al. (2021) können die bestehenden Kalibrierungsmethoden auch nach vier verschiedenen Kriterien klassifiziert werden: 1) auf der Grundlage manueller, iterativer und praktischer Eingriffe; 2) auf der Grundlage verschiedener informativer grafischer Vergleichsdarstellungen; 3) auf der Grundlage spezifischer Test- und Analysemethoden und 4) auf der Grundlage analytischer/mathematischer Kalibrierungsmodelle (Fabrizio and Monetti, 2015). Diese Methoden werden angewandt und die Modelle erweitert, sodass z. B. Optimierung der kleinsten Quadrate, genetische Algorithmen, Partikelschwarmoptimierung, simuliertes Annealing, Mustersuche und Bayes'sche Kalibrierung zur Anwendung kommen. Deterministische Kalibrierungsmethoden beruhen auf dem Prinzip der Minimierung der Differenz zwischen den simulierten und den beobachteten Daten, ohne dass Unsicherheiten ausdrücklich berücksichtigt werden. Diese Methoden führen häufig zu einem einzigen Parametersatz mit der besten Anpassung, im Gegensatz zur Bayes'schen Kalibrierung, die eine probabilistische Verteilung der Parameterwerte liefert.

Bei der manuellen Kalibrierung wird das Modell auf der Grundlage von Expertenwissen manuell angepasst (Harshalatha et al., 2024) wohingegen die Optimierung nach der Methode der kleinsten Quadrate versucht (Coakley et al., 2014), den besten Satz von Eingabeparametern zu finden, indem die Residuen zwischen simulierten und beobachteten Daten minimiert werden, wobei häufig gradientenbasierte oder andere numerische Optimierungsverfahren eingesetzt werden. Obwohl die Methode der kleinsten Quadrate intuitiver und einfacher zu verstehen ist, neigt sie zu suboptimalen Lösungen (Problem der lokalen Minima), erhöhter Empfindlichkeit gegenüber den Anfangsbedingungen und berücksichtigt nicht die Unsicherheiten in den Daten und der Modellstruktur. Bei optimierungsbasierten Methoden ist der genetische Algorithmus (GA) ein Evolutionsalgorithmus, der natürliche Evolutionsprozesse nachahmt, um komplexe Lösungsräume zu erkunden und optimale oder nahezu optimale Lösungen für Mehrzielprobleme zu finden (Ramos Ruiz et al., 2016). GA ist weniger anfällig für das Problem, in lokalen Minima stecken zu bleiben (Chong et al., 2021). Allerdings ist die Methode recht rechenintensiv, reagiert empfindlich auf eine Vielzahl von Hyperparametern und bietet keine Quantifizierung der Unsicherheit. In Anlehnung an den physikalischen Prozess des Glühens in der Metallurgie wird bei der Kalibrierung von Energiemodellen auf der Grundlage des simulierten Glühens versucht, schrittweise einen optimalen Parametersatz zu finden, der die beobachteten Daten auf der Grundlage einer definierten Zielfunktion wie der Summe der quadratischen Fehler oder des mittleren quadratischen Fehlers, der die Differenz zwischen den simulierten und den beobachteten Daten quantifiziert, am besten anpasst (Robertson et al., 2015). Dieses Modell hat sich zwar bei der Erzielung globaler Optima in komplexen und nichtlinearen

Modellen als wirksam erwiesen, erfordert jedoch eine Abstimmung des Kühlungsplans, hohe Rechenressourcen und kann die Unsicherheit der Modellparameter nicht quantifizieren. In der Familie der metaheuristischen Algorithmen ist die Methode der Partikelschwarm-Optimierung wirksam bei der Suche nach globalen Minima (weniger anfällig für das Verharren in lokalen Minima), aber sie neigt zur Überanpassung, liefert keine Unsicherheitsabschätzung der kalibrierten Eingangsparameter und erfordert erhebliche Rechenressourcen (Andrade-Cabrera et al., 2019; Chong et al., 2021). Eine weitere bestehende Kalibrierungsmethode ist die Mustersuche, bei der der Parameterraum durch die Bewertung der Zielfunktion an einer Reihe von Punkten um die derzeit beste Lösung herum erkundet wird und iterativ zu besseren Lösungen übergegangen wird. Diese Methode erfordert viele Funktionsauswertungen und trägt den Unsicherheiten des kalibrierten Modells nicht Rechnung (Sun et al., 2016).

Die Energieleistung von Gebäuden wird von vielen Faktoren beeinflusst, darunter Wetterbedingungen, Belegungsmuster, Gebäudehülle und -eigenschaften, die voneinander abhängig sind und die Simulation und ihre Kalibrierung komplex machen. Die Bayes'sche Kalibrierung bietet eine Möglichkeit, dieses vorhandene Vorwissen in den Kalibrierungsprozess einzubeziehen und so die Genauigkeit und Robustheit der Kalibrierung zu verbessern, insbesondere in Fällen, in denen die gemessenen oder beobachteten Daten verrauscht sind. Es ist bemerkenswert, dass diese BC Möglichkeiten bietet, die mit den Parametern und den Modellen verbundene Unsicherheit kumulativ zu quantifizieren, was für die Entscheidungsfindung im Energiemanagement und in der Politik notwendig ist, wo es ebenso nützlich ist, die Bandbreite möglicher Szenarien sowie das wahrscheinlichste zu kennen, um fundierte Entscheidungen treffen zu können. Energiemodelle für Gebäude sind in der Regel komplex und beinhalten nichtlineare Beziehungen und Wechselwirkungen zwischen den Parametern. Die Bayes'sche Kalibrierung ist flexibel genug, um mit dieser Komplexität umzugehen und eignet sich daher für eine genaue Simulation des Wärmeenergiebedarfs.

7.2 Ziel 2

Definition der erforderlichen Daten für die Ausführung des implementierten Bayes'schen Kalibrierungsframeworks

Wie bereits in Kapitel 3.2 erwähnt, stellte die *BIM Berliner Immobilienmanagement GmbH* eine Datenbank mit Informationen zu 978 Nichtwohngebäuden in Berlin, Deutschland, zur Verfügung. Diese Datenbank diente als Grundlage für ein früheres Projekt namens DATES - Digitales Analyse-Tool für Energetische Sanierungsfahrpläne (Wilke et al., 2020), das vom Berliner Energiefonds von Juli 2018 bis Juni 2020 gefördert wurde. Die Datenbank wurde dann später von diesem aktuellen Projekt übernommen. Für jede Liegenschaft sind die jährlichen Daten der gemessenen Wärmeenergie von 2010 bis 2017 verfügbar. Die Datenbank liefert wesentliche Daten zu Eigenschaften, Lage, technischen Anlagen und Typologie von Gebäuden mit acht verschiedenen Nutzungsarten, wie Allgemeiner Bestand, Gerichte, Schulen, Polizei, Feuerwehr, Kultur, JVA, Externe Mieter und Flüchtlingsunterbringung. Da die vererbte Datenbank während des gesamten DATES-Projekts als Backup verwendet wurde, enthält sie über die bloße Speicherung der wichtigsten Ergebnisse hinaus eine Fülle von Informationen aus verschiedenen Phasen des Projekts. Folglich musste eine gründliche Bestandsaufnahme durchgeführt werden, um festzustellen, welche Daten für die Verwendung im aktuellen Projekt am relevantesten und genauesten sind. Während Informationen zu Gebäudeeigenschaften für alle Gebäude verfügbar waren, waren Daten zu technischen Systemen - wie Lüftung, Heizung und Kühlung - oft unvollständig oder fehlten.

Die ursprüngliche Datenbank enthielt Informationen über 978 Gebäude, aber nur 183 davon waren Einzelgebäude mit eindeutigen Daten über den gemessenen Energieverbrauch. Für die übrigen Gebäude

waren die gemessenen Energiedaten nur auf der Ebene der Liegenschaft verfügbar, die mehrere Gebäude umfasst, und nicht für einzelne Strukturen. Folglich wurden diese Gebäude von der Analyse ausgeschlossen, da für die Kalibrierung direkte Messdaten für jedes Gebäude erforderlich sind, was das spezifische Ziel des Kalibrierungsprozesses ist. Ein statistischer Überblick über die Datenbank, einschließlich der Anzahl der Gebäude innerhalb jeder Liegenschaft und der Anzahl der Einzelgebäude, ist in Tabelle 1 dargestellt.

Tabelle 1 gibt einen Überblick über die Gebäudenutzungsarten und zeigt die Anzahl der zusammengefassten und der einzelnen Gebäude innerhalb jeder Nutzungskategorie

Gebäudenutzer	Gesamtbetrag der Gebäude	Anzahl der Einzelgebäude
<i>Allgemeiner Bestand</i>	110	42
<i>Gerichte</i>	33	13
<i>Schulen</i>	195	18
<i>Polizei</i>	244	21
<i>Feuerwehr</i>	105	51
<i>Kultur</i>	90	31
<i>JVA</i>	130	3
<i>Externe Mieter</i>	5	0
<i>Flüchtlingsunterbringung</i>	52	3
<i>K.A.</i>	14	1
Insgesamt	978	183

Nach einer umfassenden Überprüfung der bestehenden Datenbank wurden die einschlägigen Informationen in eine neu eingerichtete Datenbank migriert. MariaDB wurde als Datenbankmanagementsystem für dieses Projekt ausgewählt, vor allem um die effiziente Speicherung, Abfrage und Bearbeitung wichtiger Daten zu erleichtern. MariaDB, ein quelloffenes relationales Datenbankmanagementsystem (RDBMS) und eine Abspaltung von MySQL, organisiert Daten in strukturierten Tabellen, die mit der Structured Query Language (SQL) abgefragt werden können. Die Wahl fiel auf dieses System wegen seiner Zuverlässigkeit und Kompatibilität mit den Datenanforderungen des Projekts sowie wegen der einfachen Integration mit Python, da auch der Rest des Projekts mit Python entwickelt werden sollte.

Alle relevanten Daten, die für die Entwicklung des Gebäudeenergiemodells erforderlich sind, wurden gesammelt, systematisch organisiert und in einer speziellen Datenbank gespeichert. Dazu gehören auch die gemessenen Energiedaten, die während des Kalibrierungsprozesses als Referenz dienen. Da je nach ausgewähltem Gebäudeenergiemodell eine weitere Datenverarbeitung erforderlich sein könnte, wurde beschlossen, die Daten in einer Datenbank zu speichern, die über Python leicht zugänglich ist. Dies ermöglicht ein effizientes Abrufen, Verarbeiten und Reintegrieren der Daten zurück in dieselbe Datenbank. Die spezifischen Methoden, die für diesen Prozess verwendet wurden, werden im Zusammenhang mit dem folgenden Ziel unten detailliert beschrieben.

7.3 Ziel 3

Auswahl eines geeigneten und interoperablen Gebäudeenergiemodells zur Bewertung der Robustheit und Effizienz des implementierten Bayes'schen Kalibrierungsframeworks.

Nach der Organisation aller verfügbaren Gebäudeinformationen war es notwendig, ein geeignetes Gebäudeenergie-Simulationswerkzeug zu definieren, um die Gebäudeenergiemodelle zu entwickeln und später zu kalibrieren. Die Auswahl eines Simulationswerkzeugs kann von den folgenden Faktoren beeinflusst werden (Muslim, 2021):

- **Ausreichend genau:** Das Werkzeug zur Simulation der Gebäudeleistung sollte das Verhalten eines Gebäudes genau wiedergeben.

- **Das Simulationswerkzeug sollte auf die in Betracht gezogene Entwurfsoption abgestimmt sein:** Dies bedeutet, dass das Gebäudeenergiemodell die Parameter enthalten sollte, die als Merkmale der Gebäude angegeben sind. Darüber hinaus müssen die Eingabeparameter für das Simulationswerkzeug mit den in der vorhandenen Datenbank verfügbaren Parametern übereinstimmen. Dieser Abgleich stellt sicher, dass die erforderlichen Daten ausreichen, um mit dem gewählten Simulationswerkzeug ein robustes Modell zu erstellen. Ebenso wichtig ist die Anforderung, dass die Modellergebnisse die interessierenden Metriken umfassen. In diesem Fall ist der Wärmeenergiebedarf eine wichtige Ausgabe des Modells, da er mit den uns vorliegenden Messdaten übereinstimmt.
- **Das Simulationswerkzeug sollte die Analyse aller in Frage kommenden Optionen ermöglichen:** Das Modell sollte flexibel und umfassend genug sein, um die Analyse eines breiten Spektrums von Variablen zu ermöglichen und mehrere Szenarien testen zu können. Dies ist wichtig für den Kalibrierungsprozess, damit verschiedene Parameter und Szenarien geändert und bewertet werden können, um das beste Modell zu finden, das die Realität am besten widerspiegelt.
- **Das Simulationswerkzeug sollte ein Gleichgewicht zwischen der Geschwindigkeit der Analyse und der Reproduzierbarkeit der Ergebnisse herstellen:** Es sollte rechnerisch effizient sein, um den Ressourcenbedarf zu minimieren. Diese Effizienz ist insbesondere während der Kalibrierung entscheidend, die ein iterativer Prozess ist, der eine beträchtliche Anzahl von Proben und Simulationen erfordert. Diese Effizienz ist auch für künftige Anwendungsfälle von entscheidender Bedeutung, um sicherzustellen, dass die Nutzer das System innerhalb eines angemessenen Zeitrahmens ausführen können.
- **Das Simulationswerkzeug sollte in der Lage sein, das Verhalten der Bewohner zu modellieren:** Der endgültige Energiebedarf wird maßgeblich von den internen Lasten und den Belegungsplänen beeinflusst. Da diese Faktoren je nach Art der Gebäudenutzung, die in der Datenbank dargestellt wird, stark variieren, ist die Einbeziehung des Nutzerverhaltens in die Simulation für eine genaue und realistische Vorhersage des Energiebedarfs unerlässlich.
- **Das Simulationswerkzeug sollte in der Lage sein, die Heizungs-, Kühlungs- und Energieübertragungssysteme von Gebäuden zu modellieren:** Die HLK-Systeme haben einen erheblichen Einfluss auf den Endenergieverbrauch eines Gebäudes auf der Grundlage des Energiebedarfs. Da die gemessenen Daten häufig von Energierechnungen abgeleitet werden, ist die genaue Berücksichtigung der Effizienz dieser technischen Systeme für eine zuverlässige Bewertung des Energieverbrauchs unerlässlich.

Ein weiterer kritischer Aspekt in diesem Rahmen, der über die zuvor vorgestellten Kriterien hinausgeht, ist die Automatisierungsfähigkeit des Gebäudesimulationstools. Da der Kalibrierungsprozess eine beträchtliche Anzahl von iterativen Simulationen erfordert, muss das Tool einen automatisierten Betrieb ermöglichen, anstatt sich auf die manuelle Einrichtung und die Extraktion der Ergebnisse zu verlassen. Darüber hinaus ist die Betonung der Automatisierung wichtig, um sicherzustellen, dass künftige Nutzer das endgültige Bayes'sche Kalibrierungswerkzeug mit minimaler Interaktion nutzen können, was die Zugänglichkeit und Effizienz verbessert.

Nach der Evaluierung mehrerer Gebäudeenergie-Simulationswerkzeuge erwies sich DIBS als die geeignetste Option, basierend auf den oben genannten und weiter unten begründeten Kriterien.

Die DIBS spiegelt das Gebäudeverhalten genau wider. Wie in Abbildung 1 dargestellt, liegt das Verhältnis zwischen simuliertem und gemessenem Heizenergieverbrauch um den idealen Wert von 1,

was bedeutet, dass die Simulationsergebnisse eng mit den tatsächlichen Energieverbrauchsdaten übereinstimmen. Dieses Ergebnis stimmt auch mit der bereits erwähnten Studie des New Buildings Institute (2008) überein, die berichtet, dass dieses Verhältnis zwischen 0,36 und 2 bei einer großen Anzahl von Modellergebnissen im Vergleich zu gemessenen Daten variiert.

DIBS erfordert eine geringe Anzahl von Eingabeparametern, was von Vorteil ist, da die vorliegende Datenbank nur grundlegende Gebäudeattribute und begrenzte Informationen über die technischen Systeme enthält, wobei für viele Gebäude diesbezüglich keine vollständigen Daten vorliegen. DIBS benötigt in erster Linie Informationen über die Gebäudehülle sowie grundlegende Angaben über das Heiz-/Kühlsystem, z. B. ob es sich um ein wasser- oder luftbasiertes System handelt, das mögliche Vorhandensein einer Lüftungswärmerückgewinnung und die Art der Energiequellen. Spezifische Betriebsdetails der technischen Systeme folgen den Richtlinien des TEK-Tools 9.24 und müssen nicht explizit definiert werden. Dies ist vorteilhaft, da in den meisten Fällen solche detaillierten Daten in den Gebäudedatenbanken fehlen. Interne Lasten werden automatisch auf der Grundlage von Gebäudetyp und Nutzerkategorie bestimmt, wobei stündliche Zeitpläne aus ISO 13790:2008 verwendet werden. Dies ist ein erheblicher Vorteil, da die Erfassung dieser Informationen oft schwierig ist und diese Details in der Datenbank fehlten. Darüber hinaus ist die Einhaltung der deutschen Normen durch die DIBS besonders praktisch, da sich alle untersuchten Gebäude in Berlin befinden.

Im Vergleich zu anderen Gebäudeenergie-Simulationstools führt DIBS Energiesimulationen wesentlich schneller durch. Es berechnet den stündlichen Heizenergieverbrauch für ein ganzes Jahr im Durchschnitt in nur 1,3 Sekunden. Diese Geschwindigkeit ist, wie bereits betont, aufgrund des iterativen Charakters des Kalibrierungsprozesses, der die Durchführung zahlreicher Simulationen erfordert, von entscheidender Bedeutung.

Darüber hinaus ist DIBS ein Python-basiertes Tool, das eine nahtlose Integration mit anderen Schritten und die Einbindung in das gesamte Framework ermöglicht. Die Python-Grundlage ermöglicht auch eine einfache Anpassung an die spezifischen Anforderungen des Frameworks. Es wurden mehrere Änderungen vorgenommen, wie z. B. die Optimierung der Berechnungen, um nur die notwendigen Ausgaben zu liefern und die Simulationsgeschwindigkeit weiter zu verbessern. Ursprünglich verwendete das Tool Klimadaten aus dem Testreferenzjahr, aber es wurde aktualisiert, um aktuelle Klimadatendateien einzubeziehen, so dass Simulationen für jedes beliebige Jahr durchgeführt werden können. Eine weitere Verbesserung bestand darin, das Tool so anzupassen, dass es Simulationen für bestimmte Zeitintervalle durchführt, anstatt nur für das gesamte Testreferenzjahr. Außerdem können die Zeitauflösungen für die Ausgabe nun auf tägliche, wöchentliche, monatliche oder andere Intervalle angepasst werden, anstatt auf jährliche Ausgaben beschränkt zu sein. Die Eingabeparameter wurden außerdem so geändert, dass sie nicht mehr fest oder kategorisch, sondern kontinuierlich sind. Dies ermöglicht die Definition von Wahrscheinlichkeitsverteilungen und die Erkundung eines unendlichen Bereichs von Parameterwerten während des Kalibrierungsprozesses.




Abbildung 1 zeigt die DIBS-Simulationsergebnisse geteilt durch die gemessenen Daten, mit einer Trendlinie bei $y=1$. Diese Linie stellt eine perfekte Übereinstimmung dar, wobei ein Wert von 1 anzeigt, dass die Simulationsausgabe genau mit den gemessenen Daten übereinstimmt, was eine ideale Ähnlichkeit mit den tatsächlichen Bedingungen widerspiegelt.

Nach der Auswahl von DIBS als Gebäudesimulationstool und der Durchführung der erforderlichen Anpassungen mussten die Datenbankinformationen verarbeitet werden, um sicherzustellen, dass die Parameterwerte mit den erforderlichen Formaten des Modells übereinstimmen. Zu diesem Zweck wurde ein Python-Skript entwickelt, das auf einer Reihe von Regeln basiert, die aus Expertenwissen und logischen Schlussfolgerungen abgeleitet wurden. Dieser manuelle Prozess erforderte einen erheblichen Aufwand, um eine Logik zu entwerfen, die den verschiedenen Datentypen in der Datenbank gerecht wird. Das Skript liest die Originaldaten, wendet die festgelegten Regeln an und gibt die erforderlichen Parameter im richtigen Format aus. Dieser automatisierte Ansatz war unerlässlich, um die große Datenmenge effizient zu verarbeiten und alle Gebäude für das Energiemodell vorzubereiten.

Die endgültigen Eingabeparameter für das Modell sind in Tabelle 2 aufgeführt. Bei der Verarbeitung der Rohdaten wurde jedem Parameter ein Unsicherheitsgrad zugewiesen, je nachdem, ob die Informationen direkt aus der Datenbank abgerufen werden konnten oder ob Schlussfolgerungen und Annahmen erforderlich waren. Diese Unsicherheitsgrade spiegeln die vorherigen Unsicherheiten bezüglich der spezifischen Parameter und ihrer Werte wider. Die Einbeziehung von Vorabüberzeugungen in die Kalibrierung empfindlicher Parameter erfordert die Charakterisierung von Vorab-Wahrscheinlichkeitsverteilungen. Wie Chong und Menberg (2018) gezeigt haben, kann ein informativer Prior durch eine Normalverteilung mit einer kleinen Standardabweichung, ein schwach informativer Prior durch eine Normalverteilung mit einer großen Standardabweichung und ein nicht informativer Prior durch eine Gleichverteilung approximiert werden. Diese Prioritäten können auf der Grundlage von vorhandener Literatur, Expertenwissen oder aus der Datenbank extrahierten Daten formuliert werden und stellen unsere anfänglichen Annahmen über Parameterwerte dar, bevor neue Daten beobachtet werden.

Tabelle 2 Anforderungen an die Eingangsparameter der modifizierten DIBS, die an den Rahmen angepasst sind, und ihr vordefinierter Unsicherheitsgrad

Eingangsparameter	Einheit	Grad der Unsicherheit
Maximale Belegung	Anzahl Personen	Wenig Informationen
Außenwandfläche über Gelände	m^2	Vorhandene Informationen
Flächenverhältnis Fenster/Wand	-	Vorhandene Informationen
Fläche der Fassade	m^2	Vorhandene Informationen
Nordfassade	m^2	Keine Informationen
Dachfläche	m^2	Vorhandene Informationen
Nettoraumfläche	m^2	Vorhandene Informationen
Energiebezugsfläche	m^2	Vorhandene Informationen
Anzahl der Geschosse ohne Keller	-	Vorhandene Informationen
Wärmerückgewinnung der RLT	-	Wenig Informationen
Höhe	m	Vorhandene Informationen
U-Wert Fenster	$W/(m^2, K)$	Wenig Informationen
U-Wert Außenwand	$W/(m^2, K)$	Wenig Informationen
U-Wert Dach	$W/(m^2, K)$	Wenig Informationen
U-Wert Bodenplatte	$W/(m^2, K)$	Wenig Informationen
Wärmekapazität	J/K	Keine Informationen
Heizeffizienz	-	Keine Informationen
Transmissionsfaktor Glas	-	Keine Informationen
Lichttransmissionsfaktor	-	Keine Informationen
Beleuchtungsichte	$W/(m^2, lx)$	Keine Informationen
Faktor der Lichtbereitstellung	-	Keine Informationen

7.4 Ziel 4

Einrichtung eines Sensitivitätsanalysewerkzeugs innerhalb des Frameworks, um den Parameterraum der Simulationseingangsparameter zu analysieren und die empfindlichsten Parameter für die anschließende Kalibrierung zu ermitteln.

Im Zusammenhang mit Gebäudeenergiesystemen sind die Parameter, die das mathematische Modell charakterisieren, nicht immer mit Sicherheit bekannt, so dass es angebracht ist, den gesamten relevanten Parameterraum zu analysieren. Diese Analyse hilft bei der Quantifizierung des Bereichs der Modellergebnisse und der Identifizierung der Parameter, die den größten Einfluss auf das Modellverhalten und die Ergebnisse haben. Darüber hinaus wird die Bayes'sche Kalibrierung mit einer höheren Anzahl von Kalibrierungsparametern unwirksam, da die Parameter nicht identifizierbar sind und die Konvergenz von deterministischen, frequentistischen und Bayes'schen Techniken bei moderaten Parameterdimensionen schwierig ist. Diese Komplexität entsteht dadurch, dass die Parameter nicht eindeutig durch die Daten bestimmt werden, was zu Schwierigkeiten bei der genauen Ableitung von Posterior-Verteilungen führt. Dieses Problem wird durch die Modellkalibrierung auf aktiven Unterräumen angegangen, die lineare Kombinationen von Parametern sind und eine effektivere Kalibrierung ermöglichen, indem sie die Dimensionalität des Kalibrierungsparameterraums reduzieren und die Konvergenz der Kalibrierungsverfahren verbessern (Lewis et al., 2017). Daher wird in dieser Studie ein Rahmen verwendet, der bis zu den 5 einflussreichsten Parametern kalibriert, die durch eine umfassende Sensitivitätsanalyse ermittelt wurden. Dieser Ansatz mindert das Risiko einer Überparametrisierung und verbessert gleichzeitig die Berechnungseffizienz und Robustheit des Modellkalibrierungsprozesses erheblich.

Bei der Sensitivitätsanalyse wird untersucht, wie die Unsicherheit in der Ausgabe eines Modells verschiedene Quellen der Unsicherheit in den Modellinputparametern zugeordnet werden kann (Saltelli

und Sobol', 1995). Es gibt verschiedene Stichprobenverfahren zur Erzeugung von Stichproben von Eingangsparametern, darunter Monte Carlo Sampling, Latin Hypercube Sampling, Sobol Sampling und die anschließende Analyse des Einflusses jedes erzeugten Parameterstichprobenraums auf den Output mit Hilfe von globalen Sensitivitätsanalysetechniken wie der Morris-Methode, dem Fourier Amplitude Sensitivity Test (FAST) und der Sobol Sensitivitätsanalyse. Die Wahl der Stichprobenmethode und der globalen Sensitivitätsanalyse kann einen großen Einfluss auf die Genauigkeit, die Berechnungseffizienz und die Interpretierbarkeit der Ergebnisse der Sensitivitätsanalyse haben. Im Zusammenhang mit der Energiemodellierung von Gebäuden hängt die Wahl der Methode von verschiedenen Faktoren ab, wie z.B. der Komplexität des Modells, der Anzahl der Eingabeparameter, den verfügbaren Rechenressourcen und den spezifischen Forschungsfragen, die behandelt werden.

Monte-Carlo-Stichproben (Macdonald, 2009) ist zwar einfach zu implementieren, erfordert jedoch eine große Anzahl von Stichproben, um genaue Ergebnisse zu erzielen, insbesondere bei hochdimensionalen Problemen, wie sie bei Energiemodellen für Gebäude auftreten (Burhenne et al., 2011). Bei Gebäudeenergieanwendungen kann dies bei komplexen Modellen zu prohibitiv langen Berechnungszeiten führen (Tian et al., 2018). Das Latin-Hypercube-Sampling bietet häufig eine effizientere Alternative, die eine bessere Abdeckung des Parameterraums mit weniger Stichproben gewährleistet, was bei Gebäudeenergieanalysen erfolgreich angewandt wurde, um den Rechenaufwand zu verringern und gleichzeitig die Genauigkeit zu erhalten (Hopfe und Hensen, 2011). Das Saltelli-Sampling, eine Erweiterung der Sobol-Sequenzen, ist besonders nützlich für die Sobol-Sensitivitätsanalyse, da es eine effiziente Schätzung sowohl der Haupteffekte als auch der Interaktionseffekte höherer Ordnung zwischen Parametern ermöglicht (Saltelli et al., 2010).

Was die globalen Sensitivitätsanalyseverfahren betrifft, so ist die Morris-Methode rechnerisch effizient und bietet ein gutes Screening der einflussreichen Parameter, so dass sie sich für Modelle mit einer großen Anzahl von Inputs eignet (Campolongo et al., 2007). Sie kann jedoch komplexe, nicht lineare Beziehungen zwischen Inputs und Outputs nicht erfassen. Der Fourier-Amplituden-Sensitivitätstest (FAST) und die Sobol-Sensitivitätsanalyse bieten umfassendere Einblicke, einschließlich der Möglichkeit, Interaktionseffekte zu quantifizieren, allerdings zu höheren Rechenkosten (Cukier et al., 1973; Saltelli et al., 1999). Bei Anwendungen im Bereich der Gebäudeenergie haben diese Methoden ihre überlegene Fähigkeit zur Ermittlung sowohl direkter als auch interaktiver Auswirkungen von Gebäudeparametern auf den Energieverbrauch bewiesen (Rivalin et al., 2018).

In den späten 1990er und frühen 2000er Jahren wurden mehrere Studien (Borgonovo, 2007; Jacques et al., 2006; Saltelli et al., 2002, 1999; Sobol', 2001) dargestellt, wie wichtig es ist, die Wechselwirkung zwischen den Eingangsparametern und dem Modellergebnis zu berücksichtigen. Daher wird in dieser Studie das Sobol-Sampling gefolgt von der Sobol-Sensitivitätsanalyse verwendet, einem robusten Ansatz zur Erkundung des Parameterraums und zur Quantifizierung der Bedeutung der Parameter in komplexen Modellen (Saltelli et al., 2007). Das Saltelli-Sampling, eine Verbesserung der ursprünglichen Sobol-Sequenzen (Sobol', 1967) bietet eine effiziente Abdeckung des Parameterraums und wurde speziell für die Sensitivitätsanalyse entwickelt, wodurch sie für die Erstellung von Energiemodellen mit zahlreichen Eingaben entscheidend ist (Saltelli et al., 2010). Die Sobol-Methode zur Sensitivitätsanalyse, detailliert beschrieben (Sobol', 2001) bietet umfassende Einblicke sowohl in die Haupteffekte als auch in die Wechselwirkungen zwischen den Parametern, was im Kontext von Gebäudeenergiesystemen besonders wertvoll ist (Menberg et al., 2016), bei denen die Parameter häufig nichtlineare und interaktive Auswirkungen haben.

Jüngste Studien im Bereich der Energiemodellierung für Gebäude haben die Wirksamkeit der Kombination fortschrittlicher Stichprobenverfahren mit der Sobol-Sensitivitätsanalyse gezeigt. Kristensen und Petersen, (2016) haben die Eignung von varianzbasierten Sensitivitätsmethoden wie der

Sobol-Analyse für detaillierte Untersuchungen von Gebäudeenergiemodellen hervorgehoben. Rivalin et al. (2018) zeigten die Wirksamkeit dieser Methoden bei der Analyse von Unsicherheiten in der Leistung neuer gewerblicher Gebäude.

Aufbauend auf diesen Erkenntnissen wird der vorliegenden Studie das Saltelli-Sampling verwendet, eine Erweiterung der Sobol-Sequenzen, in Verbindung mit der Sobol-Sensitivitätsanalyse. Diese Kombination bietet mehrere Vorteile. Saltelli et al. (2010) haben gezeigt, dass das Saltelli-Sampling im Vergleich zu den ursprünglichen Sobol-Sequenzen ein effizienteres Mittel zur Schätzung von Sobol-Indizes darstellt.

Darüber hinaus entspricht die Wahl des Saltelli-Samplings mit Sobol-Sensitivitätsanalyse in dieser Studie dem aktuellen Best Practice auf diesem Gebiet. Sie bietet ein optimales Gleichgewicht zwischen rechnerischer Effizienz und umfassenden Sensitivitätsinformationen, die eine gründliche Untersuchung der Wechselwirkungen zwischen den Parametern und ihrer Auswirkungen auf die Energieeffizienz des Gebäudes ermöglichen (Tian et al., 2018).

Daher wird nach der Integration des Modells eine Sensitivitätsanalyse durchgeführt, um die Eingangsparameter zu ermitteln, die den größten Einfluss auf die Ergebnisse des Modells haben. Mit Hilfe der Saltelli-Sampling-Technik wird ein einheitlicher und umfassender Satz von Parameterkombinationen generiert und anschließend zur Simulation des Modelloutputs verwendet. Im nächsten Schritt wird der Sobol-Sensitivitätsindex berechnet, mit dem die Sensitivität der einzelnen Parameter bestimmt wird. Die Parameter mit den höchsten Sensitivitätsindizes werden dann für die weitere Kalibrierung ausgewählt.

Automatisierte Bestimmung des Stichprobenumfangs für Sensitivitätsanalysen:

Die Auswahl einer angemessenen Stichprobengröße ist von zentraler Bedeutung für die genaue Bestimmung der Parameter, die den größten Einfluss auf das Modellergebnis ausüben. Bei der Sensitivitätsanalyse geht es darum, die proportionalen Auswirkungen verschiedener Unsicherheitsquellen auf die Variabilität der Ergebnisse eines Modells zu bewerten. Die Hauptmotivation, den richtigen Stichprobenumfang zu finden, besteht darin, ein Gleichgewicht zwischen der Effizienz der Berechnungen und der Genauigkeit der Ergebnisse herzustellen, indem der Stichprobenumfang auf dem optimalen erforderlichen Minimum gehalten wird.

In der vorliegenden Arbeit beginnt die Analyse aufgrund der rechenintensiven Natur der Simulation mit einer begrenzten Anzahl von Stichproben. Der Stichprobenumfang wird dann systematisch erhöht, und die Simulationen werden so lange wiederholt, bis sich die Rangfolge des Sobol-Sensitivitätsindex stabilisiert hat, was darauf hindeutet, dass die Sensitivitätsreihenfolge der Parameter konsistent ist. Durch diesen iterativen Ansatz wird sichergestellt, dass die Ergebnisse robust und zuverlässig sind und ein umfassendes Verständnis der Parametereinflüsse auf die Ergebnisse des Modells ermöglichen. Mit zunehmender Stichprobengröße wird die Konvergenz der Indizes überwacht, um sicherzustellen, dass die Schätzungen nicht nur stabil sind, sondern auch die zugrunde liegende Dynamik des untersuchten Systems genau wiedergeben. Die Sobol-Sensitivitätsindizes wurden für die Konvergenz der Sensitivitätsanalyse ausgewählt, da sie eine detaillierte Quantifizierung des Einflusses der Eingangsparameter auf den Output eines Modells ermöglichen. Sie messen nicht nur die individuellen Auswirkungen der einzelnen Parameter, sondern auch die Wechselwirkungen zwischen ihnen und bieten so eine ganzheitliche Sicht auf die Bedeutung der Parameter. Bei der Sobol-Methode wird die Varianz des Outputs in die Beiträge der einzelnen Parameter und ihrer Wechselwirkungen zerlegt.

Dadurch können die Forscher feststellen, welche Parameter den größten Einfluss haben und wie sie zusammenwirken, was zu einem besseren Verständnis des Systemverhaltens führt. Im Gegensatz zu einigen Methoden der Sensitivitätsanalyse, die von linearen Beziehungen ausgehen, können Sobol-Indizes komplexe, nicht-lineare Wechselwirkungen erfassen. Dies ist besonders vorteilhaft bei Systemen, in denen die Parameter nicht unabhängig voneinander wirken, da sie aufzeigen, wie die kombinierten Auswirkungen der Parameter zu unterschiedlichen Ergebnissen führen können. Außerdem sind Sobol-Indizes relativ einfach zu interpretieren. Sie liefern eine klare Rangfolge der Wichtigkeit von Parametern, die als Entscheidungshilfe bei der Modellentwicklung und -optimierung dienen kann.

Nach Abschluss der Sensitivitätsanalyse werden die fünf Parameter, die die höchsten Sobol-Indizes aufweisen, für weitere Untersuchungen ausgewählt. Diese Parameter werden anschließend im Kalibrierungsprozess und bei der Erstellung eines Metamodells verwendet. Dieser Ansatz, sich auf die einflussreichsten Parameter zu konzentrieren, wie sie durch die Sobol-Indizes identifiziert wurden, dient der Optimierung des Kalibrierungsprozesses, indem die Dimensionalität des Parameterraums reduziert wird. Außerdem wird die Effizienz der Metamodellerstellung durch die Konzentration auf die Faktoren, die den größten Einfluss auf die Variabilität des Modells haben, erhöht.

7.5 Ziel 5

Aufbau eines auf einem Gaußschen Prozess basierenden Metamodells als Ersatzmodell für den ursprünglichen Energiebedarfssimulator, da die ursprünglichen Simulatoren oft rechenintensiv sind.

Die Bayes'sche Kalibrierung ist ein rechenintensiver Prozess, der die Durchführung zahlreicher Simulationsiterationen mit einer Reihe verschiedener Parameterwerte aus dem Parameterraum erfordert, was umfangreiche Simulationsversuche notwendig macht. Aufgrund dieses erhöhten Rechenaufwands und der zeitlichen Beschränkungen im Falle komplexer Systeme kann ein Metamodell als Ersatzmodell für den ursprünglichen Simulator implementiert werden. Dieses Metamodell kann den Rechenaufwand erheblich reduzieren, indem es das Verhalten des ursprünglichen Simulators annähert, schnellere Auswertungen ermöglicht und die Erkundung des Parameterraums effizienter macht. Bei der Bayes'schen Kalibrierung werden zahlreiche Iterationen der BEM-Simulation mit einer Reihe verschiedener Parameterwerte aus dem Parameterraum durchgeführt, was eine erhebliche Anzahl von Simulationsversuchen erfordert. Um dies zu umgehen, muss ein Metamodell in das Framework integriert werden.

Aus der Literatur geht hervor, dass zu den am häufigsten verwendeten Ersatzmodellen Gaussian Process Regressor, Polynomial Chaos Expansion, Künstliche Neuronale Netze (ANN), Support Vector Machines, Random Forest, Radial Basis Function Networks, Ensemble Methods und Deep Learning gehören. Die Polynomial Chaos Expansion (PCE), eine Meta-Modellierungstechnik, stellt die interessierende Ausgabe als eine Reihenentwicklung orthogonaler Polynome zufälliger Eingaben dar (Faggianelli et al., 2017; Xiu and Karniadakis, 2002). Die größte Herausforderung bei PCE liegt jedoch in der Wahl der geeigneten Ordnung und der Umgehung des Fluchs der Dimensionalität bei hochdimensionalen Problemen. In letzter Zeit wurden ANNs aufgrund ihrer Fähigkeit, komplexe und nichtlineare Beziehungen zu modellieren, häufig für die BEM-Kalibrierung eingesetzt (Herbinger et al., 2023). ANNs als Metamodell erfordern jedoch oft große Trainingsdatensätze und können zu einer Überanpassung neigen, wenn die Architektur ausreichend reguliert ist. Random Forest, ein Ensemble-Lernverfahren, hat sich aufgrund seiner Robustheit und seiner Fähigkeit, mit nichtlinearen Beziehungen umzugehen, als vielversprechend für die Energievorhersage in Gebäuden erwiesen (Wang et al., 2018; Wei et al., 2018). Auf Random Forest basierende Modelle sind jedoch in der Regel rechenintensiv und die Vorhersageleistung nimmt mit zunehmender Dimensionalität ab. Support Vector Machines bieten

eine gute Generalisierungsleistung bei der Kalibrierung von Energiemodellen für Gebäude und eine gute Vorhersageleistung selbst in hochdimensionalen Räumen (Zhao and Magoulès, 2012). Dennoch stellen die Auswahl geeigneter Kernel-Funktionen, die Hyperparameter und die Skalierbarkeit auf sehr große Datensätze eine große Herausforderung bei der Übernahme in Open-Source-Kalibrierungssysteme dar.

Kriging, das bei räumlichen Interpolationsproblemen weit verbreitet ist, dient als leistungsfähige Metamodellierungstechnik für die Energiemodellierung von Gebäuden in Fällen, in denen der ursprüngliche Simulator sehr rechenintensiv ist, da Kriging weniger Trainingsdaten benötigt (Tresidder et al., 2012). Die Vorhersageleistung von Kriging verschlechtert sich jedoch bei hochdimensionalen Eingabedaten. Eine weitere bemerkenswerte Metamodellierung, die in der Gebäudeenergiemodellierung eingesetzt wurde, sind Radiale Basisfunktionsnetzwerke (RBF) (Bamdad et al., 2020; Bornatico et al., 2013) Unabhängig davon, dass sie ein Gleichgewicht zwischen der Einfachheit der Implementierung und der Fähigkeit, komplexe Beziehungen zu modellieren, bieten, erfordert die Modellierung mit RBF eine sorgfältige Auswahl der Basisfunktionen und hat oft mit hochdimensionalen Daten zu kämpfen. Ensemblemodelle integrieren mehrere verschiedene Modelle, um die Gesamtleistung zu verbessern. Kürzlich wurden Ensemble-Modelle in der BEM angewandt, oft durch Kombination verschiedener Meta-Modelle. Obwohl Ensemble-Modelle die Fähigkeit gezeigt haben, komplexe Beziehungen durch Modellvielfalt zu erfassen, erfordert ihre Annahme in einem allgemeinen Open-Source-Framework die Auswahl geeigneter Basismodelle und die Kombination ihrer Vorhersage auf der Grundlage der vorliegenden Daten. Im Gegensatz dazu haben Deep-Learning-Modelle vielversprechende Ergebnisse bei der Bewältigung komplexer, hochdimensionaler Probleme gezeigt (Rahman et al., 2018), erfordern aber häufig größere Datensätze für das Training.

Vor diesem Hintergrund hat sich die Gaußsche Prozessregression (GPR) als Metamodell für die Bayes-Kalibrierung durchgesetzt, insbesondere wegen ihrer Fähigkeit, Unsicherheitsschätzungen zu liefern. GPR modelliert die Zielfunktion als Realisierung eines Gauß-Prozesses und bietet sowohl Vorhersagen als auch damit verbundene Unsicherheiten (Rasmussen et al., 2006). Gauß-Regressor, insbesondere in Form von Gauß-Prozess-Surrogaten, ist ein leistungsfähiges Werkzeug für die Bayes'sche Kalibrierung von Energiemodellen für Gebäude, da er in der Lage ist, mit Unsicherheiten effizient umzugehen, eine aussagekräftige Quantifizierung von Unsicherheiten zu liefern und die Rechenkomplexität zu bewältigen. Diese Eigenschaften machen es zu einer idealen Wahl für die Surrogatmodellierung im Rahmen von Gebäudeenergiesimulationen. GP-Surrogate bieten einen probabilistischen Rahmen, der die Quantifizierung der Unsicherheit in Modellvorhersagen ermöglicht, was für den Ausschluss von Parameterkonfigurationen, die nicht mit den beobachteten Daten übereinstimmen, von wesentlicher Bedeutung ist. Darüber hinaus wird diese Methode aufgrund ihrer nicht-parametrischen Natur häufig für die Modellierung von Surrogaten verwendet, da sie eine Quantifizierung der Unsicherheit im Modell ermöglicht, während sie ein glattes und kontinuierliches Verhalten aufweist. Außerdem liefert der Gauß-Prozess-Regressor eine Normalverteilung für jede Modellausgabe und nicht nur einen einzigen Wert, der die Modelldiskrepanz berücksichtigt, was die zentrale Prämisse der Bayes'schen Inferenz ist. Aufgrund seines nichtparametrischen Charakters kann sich der GP an komplexe, nichtlineare Beziehungen zwischen Inputs und Outputs anpassen, ohne dass eine vordefinierte funktionale Form erforderlich ist.

Daher wird im implementierten Framework das Metamodell, das die Eingaben auf die gewünschte Ausgabe abbildet, mithilfe der Gaußschen Regression implementiert. Darüber hinaus gewährleistet die kontinuierliche Natur der Gauß'schen Prozesse gleichmäßige Vorhersagen über den gesamten Eingaberaum. Dies ist bei Energiemodellen für Gebäude von Vorteil, wo kleine Änderungen der Parameter zu allmählichen Änderungen der Energieverbrauchsmuster führen können. Darüber hinaus

ermöglicht diese Flexibilität eine bessere Verallgemeinerung in Szenarien mit begrenzten Daten, was Gauß-Prozesse besonders nützlich für die Optimierung von Energieeffizienzstrategien macht.

Der Prozess der Meta-Modellierung beginnt mit der Generierung einer Reihe von Parameterkombinationen und den entsprechenden, aus dem Gebäudeenergiemodell abgeleiteten Ergebnissen. In Übereinstimmung mit den in der Sensitivitätsanalyse festgelegten Intervallen wird das Latin-Hypercube-Sampling technique (LHS) verwendet, um den Parameterraum angemessen zu beproben. Insgesamt ist das LHS-Verfahren für diesen Rahmen für Gauß'sche Prozessstichproben besonders geeignet, da es die Notwendigkeit einer gründlichen Erkundung des Parameterraums mit den Beschränkungen der Rechenressourcen in Einklang bringt. Die Realisierungen dieser Parameterkombinationen und die entsprechenden Ergebnisse werden zur Durchführung einer Gaußschen Regression und zur Erstellung des Metamodells verwendet. Das Metamodell wird anschließend in einem gepickten Format aufbewahrt, um den Zugriff zu erleichtern. Die Auswahl der optimalen Hyperparameter, insbesondere des Stichprobenumfangs und der Kernel-Funktion, ist von grundlegender Bedeutung für die Entwicklung eines effektiven Gaußschen Prozess-Surrogatmodells für die Bayes'sche Kalibrierung. Unser Framework implementiert einen automatisierten GP-Optimierungsansatz, bei dem der Benutzer die Grenzen für den Stichprobenbereich festlegt. Die Methodik bewertet systematisch verschiedene Kernelkonfigurationen und Stichprobengrößen, um die optimale Kombination auf der Grundlage der Vorhersageleistung des GP-Modells im Vergleich zum ursprünglichen Simulator zu ermitteln.

Die Auswahl des GP-Kerns, der am besten zu den Simulationsdaten passt, ist von entscheidender Bedeutung, da er die Kovarianzstruktur des GP definiert und folglich die Fähigkeit des Modells beeinflusst, die zugrunde liegenden Muster in den Daten zu erfassen. Die Ermittlung des besten Kerns, der zu den Simulationsdaten für die Gaussian Process Regression passt, beinhaltet einen iterativen Prozess, der die Leistung des Modells durch die Bewertung verschiedener Kernel-Funktionen und ihrer Hyperparameter optimiert. Zu diesem Zweck wird eine Reihe von Kernel-Kandidaten getestet, zu denen gängige Kernel wie die Radialbasisfunktion (RBF), Matérn und periodische Kernel gehören können. Jeder Kernel hat einen eigenen Satz von Hyperparametern, die eingestellt werden können. Dann werden vernünftige Grenzen für die Hyperparameter jedes Kerns festgelegt. Dies geschieht auf der Grundlage von Vorkenntnissen über die Daten oder durch explorative Datenanalyse. Zum Beispiel kann die Längenskala des RBF-Kerns auf der Grundlage der Skala der Eingangsmerkmale begrenzt werden. Für jeden Kernel und seine zugehörigen Hyperparameter wird das Gaußsche Prozessmodell auf dem Trainingsdatensatz trainiert. Dazu wird das Modell an die Daten angepasst und die Hyperparameter des Kerns entsprechend eingestellt. Nach dem Training wird die Leistung des Modells anhand von Metriken wie Normalized Root Mean Square Error und R^2 bewertet. NRMSE gibt Aufschluss über die Genauigkeit der Vorhersagen im Verhältnis zu den tatsächlichen Werten, während R^2 den Anteil der durch das Modell erklärten Varianz angibt. Der NRMSE ist dem RMSE vorzuziehen, da der RMSE unendlich groß werden kann, wenn die Ausgabe des Modells gleich Null ist, was insbesondere bei Monatsdaten mit höherer Auflösung ein großes Problem darstellt. Solche Nullwerte treten typischerweise in den Sommermonaten auf. Um zu vermeiden, dass irreführend hohe RMSE-Werte entstehen, die auf eine schlechte Modellleistung hindeuten, obwohl dies nicht der Fall ist, wurde NRMSE als Metrik gewählt. Dieser Ansatz entschärft das Problem aufgrund der Natur der Normalisierung und gewährleistet eine genauere Darstellung der Modellleistung. Auf der Grundlage der erhaltenen Leistungsmetriken wird die Auswahl der Kernel und ihrer Hyperparameter iterativ verfeinert. Wenn ein bestimmter Kernel einen niedrigeren NRMSE und ein höheres R^2 ergibt, kann er in den nachfolgenden Iterationen bevorzugt werden. Passen Sie die Grenzen der Hyperparameter nach Bedarf an, um auf der Grundlage früherer Ergebnisse einen breiteren oder gezielteren Bereich zu untersuchen.

Die Eignung des Surrogatmodells wird anhand von zwei wichtigen Leistungskennzahlen bewertet:

- Normalisierter mittlerer quadratischer Fehler (NRMSE) $< 7 \times 10^{-4} = 0,07 \%$.
- Bestimmungskoeffizient (R^2) $> 0,99$

Wenn beide Kriterien erfüllt sind, gelten die Kernelkonfiguration und die entsprechende optimale Stichprobengröße als validiert und werden anschließend im Bayes'schen Kalibrierungsverfahren verwendet. Dieser automatisierte Auswahlprozess gewährleistet eine robuste Leistung des Surrogatmodells bei gleichzeitiger Minimierung des Rechenaufwands.

7.6 Ziel 6

Einrichtung eines Bayes'schen Inferenz-gestützten Kalibrierungswerkzeugs innerhalb der Toolchain, das die Eingangsparameter des untersuchten Simulationsmodells effektiv feinabstimmen kann, um eine posteriore Wahrscheinlichkeitsverteilung zu erhalten, die als Input für den ursprünglichen Simulator dient, der das kalibrierte Modell darstellt.

Das Bayes-Theorem bietet einen robusten Rahmen für die Aktualisierung und Verfeinerung der Wahrscheinlichkeit einer bestimmten Hypothese angesichts neuer Beweise. Durch die Kombination neuer Beweise mit vorhandenem Wissen wird die Wahrscheinlichkeit einer Hypothese verändert und verbessert. Die Wahrscheinlichkeit der Evidenz reduziert die Anzahl der möglichen Szenarien, die auf der Evidenz basieren, und gibt vorherige Überzeugungen über die zu überarbeitende Hypothese vor. Dies kann bei der Modellkalibrierung sehr hilfreich sein, da es uns ermöglicht, einen Parameter zu ändern, je nachdem, wie gut er zu den beobachteten Daten passt, und dabei auch seine inhärente Unsicherheit zu berücksichtigen. Durch die Integration dieser beiden kritischen Aspekte in Gebäudeenergie-Simulationsmodelle kann die Fähigkeit des Modells, reale Szenarien abzuschätzen, verbessert werden (Riddle und Muehleisen, 2014).

Das Bayes'sche Theorem besagt, dass die posteriore Parameterverteilung, bezeichnet als $P(\theta|y)$, proportional zur Wahrscheinlichkeitsfunktion $P(y|\theta)$ und zur vorherigen Wahrscheinlichkeitsverteilung des Parameters $P(\theta)$ ist:

$$P(\theta \vee y) \propto P(y \vee \theta) * P(\theta) \quad (1)$$

Chong und Menberg (2018) haben in ihrer Studie gezeigt, dass ein informativer Prior durch eine Normalverteilung mit einer kleinen Standardabweichung, ein schwach informativer Prior durch eine Normalverteilung mit einer hohen Standardabweichung und ein nicht informativer Prior durch eine Gleichverteilung approximiert wird. Diese Prioritäten können mit Hilfe von Informationen aus der vorhandenen Literatur, Expertenwissen oder Datenbankextraktionen formuliert werden. Solche Verteilungen kapseln unsere anfänglichen Überzeugungen über die Parameterwerte ein, bevor wir irgendwelche Daten beobachten.

Die vorherige Wahrscheinlichkeitsverteilung stellt das vorherige Wissen über die Hypothese dar, die im vorliegenden Fall den Modelleingabeparametern entspricht, die durch eine erste Schätzung ihrer möglichen Werte definiert sind. Die Likelihood-Funktion quantifiziert die Wahrscheinlichkeit der Evidenz in Abhängigkeit von der Hypothese. Die posteriore Wahrscheinlichkeitsverteilung stellt dann die verfeinerten, aktualisierten Schätzungen der Werte der Eingangsparameter angesichts der beobachteten Daten dar. Bei der Kalibrierung des Modells werden also die vom Modell simulierten Daten iterativ mit den beobachteten Daten verglichen, um eine Verteilung möglicher Werte zu ermitteln,

die die genauesten Werte ergibt. Dieser Prozess umfasst im derzeitigen Rahmen zwei Hauptkomponenten: die Definition der Likelihood-Funktion und den Kalibrierungsprozess selbst.

Definition der Likelihood-Funktion:

Ein grundlegender mathematischer Rahmen wurde von Kennedy und O'Hagan (2001) für die Bayes'sche Kalibrierung eingeführt. Dieser Rahmen beinhaltet die Berechnung einer Likelihood-Funktion, die die Beziehung zwischen den beobachteten Daten (y), den unsicheren Parametern (θ) und den bekannten Eingaben (x) beschreibt. Die Likelihood-Funktion bewertet die Angemessenheit der Modellparameter bei der Berücksichtigung der beobachteten Daten:

$$y(x) = \eta(x, \theta) + \delta(x) + \varepsilon(x) \quad (2)$$

$\eta(x, \theta)$: Modellausgabe bei bekannten und unbekannten Parametern

$\delta(x)$: Modelldiskrepanz

$\varepsilon(x)$: Messfehler

Die Likelihood-Funktion quantifiziert somit die Wahrscheinlichkeit, die beobachteten Daten unter Berücksichtigung des Modells und seiner Parameter zu erhalten, und verknüpft so die Modellvorhersagen mit den beobachteten Daten, wobei Messunsicherheiten gebührend berücksichtigt werden.

Kalibrierungsprozess:

Der Kalibrierungsprozess für das Energiemodell beinhaltet die Aktualisierung der vorherigen Wahrscheinlichkeitsverteilungen der Parameter unter Verwendung einer Wahrscheinlichkeitsfunktion auf der Grundlage der beobachteten Daten. Bei diesem Prozess wird ein Markov-Chain-Monte-Carlo-Ansatz (MCMC) verwendet, bei dem Stichproben aus den vorherigen Verteilungen gezogen werden. Anhand dieser Parameterstichproben wird in einer Metamodell-Simulation eine Wahrscheinlichkeitsverteilung der Modellausgabe erzeugt, die die Berechnung der bedingten Wahrscheinlichkeit der beobachteten Daten in Abhängigkeit vom Modell erleichtert. Anschließend wird eine neue Parameterkombination ausgewählt, die zu einer neuen Modellausgabeverteilung führt, aus der die bedingte Wahrscheinlichkeit neu berechnet wird. Wenn die neue Parameterkombination eine höhere bedingte Wahrscheinlichkeit ergibt, werden die Parameterwerte für weitere Iterationen beibehalten. Dieser iterative Prozess wird so lange fortgesetzt, bis die gewünschte Anzahl von akzeptierten Parameterproben erreicht ist. Das Ergebnis dieses Prozesses ist die posteriore Wahrscheinlichkeitsverteilung, siehe Abbildung 2.




Abbildung 2 Veranschaulichung des Stichprobenprozesses innerhalb der Bayes'schen Kalibrierung. Gezeigt ist, wie sich die posteriore Wahrscheinlichkeitsverteilung aus der zugeordneten prioren Wahrscheinlichkeitsverteilung ergibt

Ein entscheidender Aspekt dieses Ansatzes ist die Bestimmung der Anzahl der Stichproben, die erforderlich sind, um eine repräsentative Posterior-Verteilung zu gewährleisten. Zu diesem Zweck führten Gelman und Rubin 1992 die Gelman-Rubin-Diagnose ein, die seither zu einem Standardinstrument in der Bayes'schen Inferenz geworden ist, um zu beurteilen, ob MCMC-Ketten die Posterior-Verteilung ausreichend erforscht haben (Gelman et al., 1992). Die Gelman-Rubin-Statistik vergleicht die Varianz zwischen mehreren MCMC-Ketten (Between-Chain-Varianz) mit der Varianz innerhalb jeder Kette (Within-Chain-Varianz). Konvergenz ist gegeben, wenn diese Varianzen annähernd gleich sind, was zu einem Wert der Gelman-Rubin-Statistik nahe 1 führt.

Im vorliegenden Rahmen wird diese Diagnose durch die gleichzeitige Entnahme von Stichproben für vier Ketten berücksichtigt. Die Anzahl der erforderlichen Stichproben wird schrittweise erhöht, und der Kalibrierungsprozess wird so lange wiederholt, bis das Konvergenzkriterium der Gelman-Rubin-Statistik einen Wert von $1,0 \pm 0,1$ erreicht. Durch diese Automatisierung entfällt die Notwendigkeit, die Anzahl der Stichproben manuell festzulegen, was die Robustheit und Effizienz des Systems erhöht.

Sobald der Kalibrierungsprozess abgeschlossen ist, dienen die akzeptierten Mittelwerte als Posterior-Wahrscheinlichkeitsverteilungen der Parameter. Dieser Schritt führt zu den posterioren Wahrscheinlichkeitsverteilungen für die ermittelten Parameter. Die Bayes'sche Kalibrierung hilft bei der Bewertung der Unsicherheit der Modellergebnisse. Einer der Hauptvorteile der GP-Regression besteht darin, dass sie nicht nur Punktschätzungen der Ergebnisse, sondern auch ein Maß für die mit diesen Vorhersagen verbundene Unsicherheit liefern kann. Dies wird durch die Konstruktion von Konfidenzintervallen erreicht. Wenn ein Gauß-Prozess an die Daten angepasst wird, erzeugt er eine Verteilung für jeden Output anstelle eines einzelnen deterministischen Wertes. Diese Verteilung ist durch einen Mittelwert (die vorhergesagte Ausgabe) und eine Varianz (die die Unsicherheit quantifiziert) gekennzeichnet. Die Varianz kann verwendet werden, um Konfidenzintervalle um die vorhergesagten Ergebnisse zu konstruieren. Konfidenzintervalle stellen einen Wertebereich dar, in dem die tatsächliche Ausgabe mit einem bestimmten Maß an Sicherheit erwartet werden kann. Unter Verwendung des Mittelwerts und der Varianz aus der Posterior-Verteilung, die sich aus der Kalibrierung ergibt, kann das Konfidenzintervall wie folgt berechnet werden:

$$X_{lower,upper} = \mu \pm Z \times \sigma \quad (3)$$

$X_{lower, upper}$: Untere und obere Grenzwerte

μ : Mittelwert der nachträglichen Wahrscheinlichkeitsverteilung

Z : Z-Score für die Berechnung des spezifischen Konfidenzintervalls. Entspricht 1,645 für ein 90 % - Vertrauensintervall

σ : Standardabweichung der Wahrscheinlichkeitsverteilung

Diese Fähigkeit des auf Bayes'schen Inferenzen basierenden Kalibrierungsframeworks, Unsicherheiten zu quantifizieren, ist besonders bei komplexen Systemen wie Gebäudeenergiemodellen von Vorteil, bei denen kleine Variationen der Eingangsparameter zu erheblichen Veränderungen der Ergebnisse führen können. Indem sie eine Reihe plausibler Ergebnisse liefern, helfen Konfidenzintervalle den Entscheidungsträgern, die Zuverlässigkeit der Vorhersagen zu verstehen und die mit verschiedenen Parameterwahlen verbundenen Risiken zu bewerten. Darüber hinaus gewährleistet die kontinuierliche Natur der GP, dass diese Konfidenzintervalle über den Eingaberaum hinweg gleichmäßig sind, was einen besseren Einblick in die Entwicklung der Unsicherheit bei variierenden Eingabeparametern ermöglicht. Dies ist für die Optimierung von Energieeffizienzstrategien von Vorteil, da es den Praktikern ermöglicht, nicht nur die besten Schätzungen, sondern auch die Bandbreite möglicher Ergebnisse zu ermitteln, was zu einer fundierteren Entscheidungsfindung beiträgt.

Die Bestimmung der optimalen Anzahl von Stichproben bleibt auch in diesem Schritt eine Herausforderung. Zu diesem Zweck wird mit einer kleinen Stichprobengröße begonnen und diese schrittweise erhöht, bis der Kalibrierungsprozess konvergiert. Dieser Zustand der Konvergenz wird durch die gleichzeitige Entnahme von Stichproben aus mehreren Ketten und die Schätzung der Gelman-Rubin-Statistiken bewertet, die die Varianz innerhalb jeder Kette mit der Varianz über alle Ketten hinweg in Beziehung setzen und so abschätzen, wie gut sich die Ketten an eine gemeinsame, nicht voneinander unterscheidbare Verteilung angeglichen haben. Eine Gelman-Rubin-Statistik in der Nähe von $1,0 \pm 0,1$ für alle fünf Parameter weist auf eine zufriedenstellende Konvergenz hin, was bedeutet, dass der MCMC-Sampling-Prozess eine stationäre Verteilung erreicht hat und die resultierenden Schätzungen zuverlässig sind (Calama-González et al., 2021).

7.7 Ziel 7

Implementierung eines Bayesian Inference Integrated Calibration Frameworks für die Kalibrierung von Gebäudeenergiemodellen in Python und Bewertung, ob das implementierte Framework in der Lage ist, die Kalibrierung von Gebäudeenergiemodellen zu unterstützen, indem die in der ASHRAE-Richtlinie 14 festgelegte Kalibrierungsfehlerschwelle bewertet wird.

Die Leistung des kalibrierten Modells wurde nach den Kriterien der ASHRAE-Richtlinie 14 validiert. Das Validierungsverfahren umfasste die Ausführung des ursprünglichen Simulators unter Verwendung der Posterior-Verteilungen der kalibrierten Parameter, die aus der Bayes'schen Inferenz gewonnen wurden. Es wurden mehrere Simulationsläufe mit paralleler Verarbeitung durchgeführt, um eine umfassende Abdeckung des Parameterraums zu gewährleisten. Die Vorhersagegenauigkeit des Modells wurde anhand von zwei wichtigen Leistungskennzahlen bewertet (Risch et al., 2021) wie von ASHRAE vorgeschrieben:

- 1) Variationskoeffizient des mittleren quadratischen Fehlers (CV(RMSE)):

$$CV(RMSE) = \frac{RMSE}{\bar{y}} \times 100\% \quad (4)$$

wobei RMSE der mittlere quadratische Fehler und $\bar{y}$ der Mittelwert der gemessenen Werte ist.

- 2) Bestimmungskoeffizient (R^2):

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (5)$$

wobei $\hat{y}_i$ für die vorhergesagten Werte und $\bar{y}_i$ für die tatsächlichen Werte steht.

Der CV(RMSE)-Wert sollte 5 % für Kalibrierungen mit jährlicher Zeitauflösung und 15 % für Kalibrierungen mit monatlicher Zeitauflösung nicht überschreiten. Gleichzeitig muss der R^2 -Wert in beiden Fällen einen Mindestwert von 0,75 erreichen, um als gute Kalibrierung zu gelten. In den aktuellen Normen sind die Anforderungen für andere Zeitauflösungen, wie z. B. wöchentlich, nicht ausdrücklich festgelegt. Eine höhere zeitliche Auflösung führt im Allgemeinen zu mehr Datenpunkten und einer größeren Detailgenauigkeit, was das Fehlerpotenzial erhöhen kann. Daher deutet die Erfüllung der monatlichen Kalibrierungskriterien für wöchentliche Auflösungen auf eine robuste Kalibrierung hin. Dieser Ansatz wird in diesem Bericht angewandt.

Der Validierungsdatensatz für die Bewertung des Frameworks umfasst die verbleibenden 25 % der Messdaten, die nicht für den Kalibrierungsprozess verwendet wurden, um eine unabhängige Bewertung der Verallgemeinerungsfähigkeit des Modells zu gewährleisten. Für die Gesamtheit der Simulationsergebnisse wurde eine statistische Analyse durchgeführt, um die Vorhersageunsicherheit und Zuverlässigkeit des Modells zu quantifizieren. Weitere Ergebnisse und Schwellenwerte für das am

besten kalibrierte Modell in Bezug auf verschiedene Auflösungen auf der Grundlage der ASHRAE-Richtlinie 14 werden im folgenden Kapitel erörtert.

7.8 Zusammenfassung der Hauptziele

Die primären Forschungsziele, die die Rahmenarchitektur prägten, waren:

- Entwicklung einer automatischen Kalibrierungsmethode unter Verwendung der Bayes'schen Statistik
- Implementierung eines vollautomatischen Konvergenztests für die Sensitivitätsanalyse, die Gauß'sche Prozessregression und die Bayes'sche Kalibrierung ohne oder mit nur minimalen Eingaben durch den Benutzer
- Erzielung einer robusten Modellleistung innerhalb definierter Fehlerschwellen
- Integration von Parallelverarbeitungsfunktionen für effiziente Berechnungen

Diese Ziele führten zur Entwicklung eines umfassenden Frameworks, wie in Abbildung 3 dargestellt. Diese robuste Frameworkarchitektur, die aus der systematischen Verfolgung der Forschungsziele hervorging, umfasst die Datenvorverarbeitung, die Sensitivitätsanalyse, das Surrogatmodell und die Bayes'sche Kalibrierung. Die vollständige Implementierung des Frameworks, einschließlich aller oben beschriebenen Komponenten, ist im Git-Repository des Projekts verfügbar.



Abbildung 3 gibt einen umfassenden Überblick über die wichtigsten Ziele und Schritte bei der Entwicklung einer interoperablen Open-Source-Bayesian-Kalibrierung von Gebäudeenergiesystemen

8 Ergebnisse

In diesem Kapitel werden die Ergebnisse verschiedener Fallstudien vorgestellt, bei denen unterschiedliche Klimadatensätze und Zeitauflösungen verwendet wurden, um die Wirksamkeit des Bayes'schen inferenzgestützten Frameworks für die Kalibrierung von Energiemodellen zu bewerten. Insbesondere wird in der ersten Fallstudie untersucht, wie ein gut kalibriertes Modell zuverlässig Sanierungsstrategien vorschlagen kann, die zu messbaren Einsparungen beim Wärmeenergiebedarf führen.

Die erste Fallstudie verwendet die erste Datenbank der BIM Berliner Immobilienmanagement GmbH, während die zweite Fallstudie auf dem später erworbenen Datensatz basiert. Die erste Fallstudie konzentriert sich in erster Linie auf das Framework selbst und veranschaulicht die Anwendung verschiedener Ansätze auf Klimadaten. Im ersten Beispiel werden Klimadaten des Tatsächlichen Meteorologischen Jahres (AMY) verwendet, während im zweiten Beispiel ein Testreferenzjahr (TRY) verwendet wird, das eine noch benutzerfreundlichere Option für die Nutzer in Deutschland darstellt. In der zweiten Fallstudie wird die Leistung des Frameworks in verschiedenen zeitlichen Auflösungen bei der Kalibrierung von Gebäudeenergiemodellen unter Verwendung der AMY-Klimadaten bewertet.

In der ersten Fallstudie wird die Wirksamkeit des implementierten Frameworks bei der Kalibrierung der BEM für jährliche Energiebedarfsprognosen untersucht. Andererseits wird in der zweiten Fallstudie versucht, die Vielseitigkeit des Frameworks bei der Kalibrierung der BEM über mehrere Zeitauflösungen hinweg zu ermitteln. Die Ergebnisse zeigen, dass dieses Open-Source-Framework effektiv für zukünftige betriebliche Nachrüstungsanalysen angepasst werden kann, bei denen Kalibrierungen über verschiedene zeitliche Auflösungen entscheidend.

Die Berechnungen wurden auf einem Hochleistungsrechner durchgeführt, der mit zwei Intel Xeon 4216 Prozessoren mit insgesamt 32 Kernen bei 2,10 GHz, 192 GB RAM und einem lokalen SSD-Speicher von 430 GB ausgestattet war.

8.1 Fallstudie 1

Die erste Fallstudie basiert auf einem Datensatz, der von der BIM und enthält umfassende Details über den Standort, die Gebäudehülle, die technischen Systeme und die Nutzungsart jedes Gebäudes. Darüber hinaus enthält er jährliche, gemessene Heizenergieverbrauchsdaten von 2010 bis 2017. Dieser Abschnitt demonstriert die Anwendbarkeit des implementierten Bayes'schen Kalibrierungsmodells für die Kalibrierung des DIBS-Gebäudeenergiemodells zur Vorhersage des Heizenergiebedarfs dieser Referenzgebäude. Diese Gebäude wurde ausgewählt, um die Wirksamkeit des Kalibrierungsframeworks auf der Grundlage der verfügbaren historischen Daten aus dem Portfolio zu demonstrieren.

Es werden zwei Ansätze für die Implementierung von Klimadaten bewertet. Im ersten Fall werden die Daten des tatsächlichen meteorologischen Jahres für die Simulationen verwendet, während im zweiten Fall die Daten des Testreferenzjahres aus Potsdam, Deutschland, verwendet werden. Bei letzterem Ansatz erzeugt das DIBS-Modell einen einzigen Ausgabewert, der durch einen ortsspezifischen Klimafaktor auf der Grundlage von Jahr und Postleitzahl angepasst wird. Diese Methode erhöht die Effizienz der Berechnungen, da nur eine einzige Simulation anstelle von mehrjährigen Zeitreihenberechnungen erforderlich ist, während gleichzeitig die Notwendigkeit einer standortspezifischen Klimadatenerfassung entfällt.

Dieses Modell berücksichtigt zwar spezifische Veränderungen der Wettermuster im Laufe der Jahre durch vereinfachte Klimaanpassungsfaktoren, aber dieser beschleunigte Simulationsansatz bringt einen

Nachteil mit sich. Der Ansatz opfert die zeitliche Granularität, die in den Klimadaten des tatsächlichen meteorologischen Jahres enthalten ist.

8.1.1 Gebäudeenergiemodell

Die in Tabelle 3 aufgeführten Attribute sind spezifisch für das für die Demonstration ausgewählte Gebäude und werden als Eingabevariablen für das DIBS-Modell verwendet. Die zuvor beschriebene Datenbank besteht aus den Informationen, die für diese Attribute relevant sind. Die Attribute wurden danach kategorisiert, ob ihr zugehöriger Parameterwert direkt in der Datenbank verfügbar war oder logisch aus den vorgelegten Daten abgeleitet wurde, wodurch ihr Unsicherheitsgrad bestimmt wurde.

Die Datenbank enthielt gemessene Wärmeenergieverbrauchsdaten für den Zeitraum von 2010 bis 2017. Für das Gebäude in dieser Demonstration wurden 90 % (Jahr 2010 - 2016) der gemessenen Daten für die Kalibrierung und die restlichen 10 % (Jahr 2017) für die Bewertung des kalibrierten Modells verwendet.

Der simulierte Wärmeenergieverbrauch vor der Kalibrierung ist in den Abbildungen 4-5 im Vergleich zu den gemessenen Daten für den entsprechenden Zeitraum dargestellt. Abbildung 4 zeigt die DIBS-Ausgaben, die mit den Klimadaten des tatsächlichen meteorologischen Jahres neu abgetastet wurden, während Abbildung 5 die Ausgaben mit den Klimadaten des Testreferenzjahres zeigt, die mit Klimafaktoren angepasst wurden.

Wie ersichtlich, weicht die simulierte Leistung in beiden Fällen der TRY- und AMY-Klimadaten von den gemessenen Daten ab. Diese Diskrepanz ist wahrscheinlich auf die Tatsache zurückzuführen, dass Modelle eine Vereinfachung der Realität darstellen, sowie auf die in der Simulation verwendeten Eingabeparameter. Da die Parameterdaten von Energieversorgern und nicht aus einem kontrollierten Versuchsaufbau stammen, spiegeln sie aufgrund von Faktoren wie Datenverfügbarkeit und -qualität sowie unterschiedlichen Berichterstattungsmethoden der verschiedenen Versorger möglicherweise nicht genau die realen Bedingungen wider. Dies kann zu einer Diskrepanz zwischen dem beobachteten und dem simulierten Energiebedarf führen, was die Notwendigkeit einer Modellkalibrierung unterstreicht.




Abbildung 4 Vergleich zwischen dem simulierten und dem gemessenen Wärmeenergiebedarf vor der Kalibrierung (AMY).




Abbildung 5 Vergleich zwischen simuliertem und gemessenem Wärmeenergiebedarf vor der Kalibrierung (TRY).

Die Untersuchung der Wärmeenergieverbrauchsdaten für das Gebäude zeigt, dass das Simulationsmodell DIBS die gemessenen Werte durchweg unterschätzt, mit Abweichungen von 20-25 kWh/m² für die beiden Fälle AMY und TRY im Zeitraum 2010-2017. Während beide Datensätze ähnliche zeitliche Muster aufweisen, einschließlich eines Spitzenwerts im Jahr 2010 und eines allgemeinen Rückgangs bis 2014, unterstreicht die systematische Verzerrung der Vorhersagen die dringende Notwendigkeit einer Modellkalibrierung. Eine Bayes'sche Kalibrierung wäre hier besonders nützlich, da sie systematisch Parameterunsicherheiten angehen und dabei sowohl Vorwissen als auch beobachtete Daten einbeziehen kann, wodurch die Vorhersagegenauigkeit und Zuverlässigkeit des Modells für zukünftige Energieverbrauchsprognosen verbessert wird.

Um die Eingabeparameter zu verfeinern und ein repräsentativeres Modell zu erstellen, wird daher ein Kalibrierungsprozess durchgeführt. In der nächsten Phase wird eine Sensitivitätsanalyse durchgeführt, um den einflussreichsten Parameter zu ermitteln.

8.1.2 Sensitivitätsanalyse

Wie im vorangegangenen Kapitel hervorgehoben wurde, ist die Bestimmung einer angemessenen Anzahl von Stichproben für die SA in diesem Stadium von größter Bedeutung. Der Schlüssel zur Bestimmung des geeigneten Stichprobenumfangs liegt darin, ein Gleichgewicht zwischen der Effizienz der Berechnung und der Genauigkeit der Ergebnisse zu erreichen und gleichzeitig sicherzustellen, dass der Stichprobenumfang auf dem idealen Minimum bleibt. Diese Methode zielt darauf ab, den kleinsten Stichprobenumfang zu ermitteln, bei dem die Rangfolge der Sensitivitätsindizes der einflussreichsten Parameter stabil ist. In dieser Fallstudie wird die Sensitivitätsanalyse für einen Satz von 21 Parametern durchgeführt, die mit dem Gebäudeenergiemodell verbunden sind. Die Parameterbereiche wurden aus Vorwissen oder empirischen Daten abgeleitet, die für das zu modellierende Gebäude relevant sind. Um die optimale Stichprobengröße zu finden, wird zunächst ein Bereich für die Stichprobengröße vom Benutzer festgelegt, der in unserem Fall zwischen 2^4 bis 2^8 . Es ist zu beachten, dass die Mindestanzahl der Stichproben, N , auf 2^4 was zu 704 Parameterkombinationen ($N \times (2D+2)$) führt, und der Stichprobenumfang sollte für die Bewertung der Sensitivitätsanalyse nach Sobol auf Potenzen von 2 gesetzt werden (Saltelli, 2002). Dieser exponentielle Anstieg des Stichprobenumfangs ermöglicht eine effiziente Erkundung des Parameterraums und gewährleistet gleichzeitig einen systematischen Ansatz

für die Konvergenzprüfung. Der Gesamt-Sobol-Sensitivitätsindex konvergierte bei $N = 64$, was 2816 Stichproben entspricht und eine Stabilisierung der Sensitivitätseinstufung der ersten fünf Parameter anzeigt (siehe Abbildung 6-7). Die Konvergenz wurde in 25 Minuten für das Modell AMY mit höherem Output und in nur 5 Minuten für die TRY-Version erreicht. Auf der Grundlage dieser Ergebnisse wurden die fünf empfindlichsten Parameter für die weitere Kalibrierung ausgewählt.




Abbildung 6 Rangfolge der Parameter auf der Grundlage einer globalen Sensitivitätsanalyse (AMY)




Abbildung 7 Rangfolge der Parameter auf der Grundlage einer globalen Sensitivitätsanalyse (TRY)

Wie aus den Abbildungen 6-7 hervorgeht, zeigt die Sensitivitätsanalyse des Gebäudes eine konsistente Rangfolge der Parameter sowohl in den AMY- als auch in den TRY-Klimadatensätzen, was die Robustheit der identifizierten Einflussparameter unterstreicht. Die fünf empfindlichsten Parameter sind der U-Wert der Fenster, die Anlagenaufwandszahl, der U-Wert der Außenwände, die Leistungsdichte der Beleuchtung und der charakteristische Lampenfaktor. Die Rangfolge der Parameter stabilisiert sich mit zunehmender Anzahl der Stichproben, insbesondere nach etwa 2816 Stichproben. Diese Stabilisierung deutet darauf hin, dass der Optimierungsprozess den Parameterraum ausreichend erforscht und die einflussreichsten Parameter identifiziert hat. Diese hierarchische Sensitivität bleibt zwischen den tatsächlichen und den Referenzklimajahr-Wetterbedingungen weitgehend unverändert, was ihre Auswahl für die Bayes'sche Kalibrierung bestätigt. Weniger einflussreiche Parameter wie die Höhe, die Dachfläche und die Wärmerückgewinnungseffizienz haben nur minimale Auswirkungen auf das Modellergebnis, was ihren Ausschluss aus dem Kalibrierungsprozess rechtfertigt. Es ist auch anzumerken, dass die Konsistenz in den Top-Rankings auf eine robuste Auswahl hindeutet, was die Effektivität der nachfolgenden GP-Trainings- und Kalibrierungsschritte erhöhen wird. Die ermittelten fünf einflussreichsten Parameter wurden dann für die Modellierung nach dem Gaußschen Verfahren und die weitere Kalibrierung verwendet.

8.1.3 Gaußsches Prozess-Surrogatmodell

In dieser Phase wird ein Metamodell erstellt, das die zuvor in Tabelle 3 angegebenen Parameterwertintervalle verwendet, wie sie auch in der Sensitivitätsanalyse verwendet werden. Bei diesem Ansatz werden zunächst fünf Kombinationen von Stichprobenparametern erzeugt, wobei 75 % der Gesamtstichproben für das Training des Modells und 25 % für den Test des trainierten Modells auf Vorhersagen reserviert sind.

Die nebenstehenden Abbildungen 8-9 veranschaulichen, wie die Anzahl der Trainingsstichproben schrittweise erhöht wird, bis die festgelegten Leistungsanforderungen für das Metamodell erfüllt sind. Ein konvergentes, trainiertes Modell ist definiert als eines, bei dem der R^2 -Wert über 0,99 und der entsprechende normalisierte mittlere quadratische Fehler unter 0,07 % liegt. Bei diesem Schwellenwert wird das Metamodell als hinreichend genaues Surrogatmodell angesehen.

Bei diesem Verfahren werden mehrere Kernel gleichzeitig auf Konvergenz geprüft, anstatt sich auf einen einzigen Kernel zu konzentrieren. Dieser Ansatz hilft, den am besten passenden Kernel mit der optimalen Anzahl von Stichproben zu ermitteln. Eine spezielle Struktur wurde entwickelt, um Multiprocessing zu ermöglichen, so dass mehrere Kernel gleichzeitig ausgeführt werden können und der Prozess effizienter wird. Dadurch wird sichergestellt, dass der effektivste Kernel mit der geringsten Anzahl von Stichproben gefunden wird. Jeder Kernel wird iterativ mit unterschiedlichen Stichprobengrößen trainiert, um die optimale Anzahl von Stichproben für jeden Kernel zu ermitteln. Die Auswahl der Stichproben und der Kernel wird also durch diese Analyse bestimmt.

Die Ergebnisse zeigen, dass bestimmte Kernel bei größeren Stichproben besser abschneiden, während andere ihre Effektivität auch bei weniger Stichproben beibehalten, was die Bedeutung der Anpassung des Ansatzes an die einzigartigen Merkmale jedes Kernels unterstreicht. Außerdem zeigt die Analyse, dass die Wahl des Kernels die Verallgemeinerungsfähigkeit des Modells erheblich beeinflussen kann, was die Notwendigkeit einer sorgfältigen Auswahl unterstreicht. Die Studie unterstreicht auch die Rolle der Abstimmung der Hyperparameter bei der Verbesserung der Modellleistung und legt nahe, dass systematische Anpassungen zu erheblichen Verbesserungen bei der Modellanpassung führen können. Die folgenden Abbildungen zeigen nur den Kernel mit der besten Leistung.




Abbildung 8 Gaußsche Prozessregression für die Erstellung von Metamodellen (AMY)




Abbildung 9 Gaußsche Prozessregression für die Erstellung von Metamodellen (TRY)

Wie aus den Abbildungen 8-9 hervorgeht, zeigt die Konvergenzanalyse des Gauß-Prozess-Regressors sowohl für das tatsächliche meteorologische Jahr als auch für das Testreferenzjahr eine ausgezeichnete Leistung, wobei identische rationale quadratische Kerne verwendet werden. Für den Fall AMY wurde

die Konvergenz mit 76 Stichproben erreicht, was zu einem normalisierten RMSE von 0,063 % und einem R^2 -Wert von 1,0 führte. Im Gegensatz dazu konvergierte der TRY-Fall mit 72 Stichproben und wies etwas bessere Metriken auf (NRMSE: 0,050 %, R^2 -Wert: 1,0). Beide Fälle erfüllen erfolgreich die strengen Konvergenzkriterien (NRMSE < 0,07 %, R^2 > 0,99), was die Zuverlässigkeit des GP-Modells als Surrogat für das Gebäudeenergiemodell bestätigt. Die identische Kernalauswahl ($1 \times 2 \times \text{RationalQuadratic}(\alpha=1, \text{length_scale}=1)$) für beide Wetterdatensätze zeigt außerdem die Robustheit des Surrogatmodellierungsansatzes.

Die Konvergenz wurde in weniger als 20 Minuten für den AMY-Fall erreicht, bei dem mehr Ausgaben zu regressieren sind und daher mehr Rechenressourcen benötigt werden. Der TRY-Fall hingegen konvergierte in knapp über 2 Minuten. Die trainierten Modelle werden in einem Format gespeichert, um einen bequemen Zugriff zu ermöglichen, und werden später im Kalibrierungsverfahren verwendet.




Abbildung 10 Ursprüngliche Modellausgabe (DIBS) im Vergleich zur Ausgabe des trainierten Metamodells (AMY)

Der Vergleich zwischen DIBS (ursprüngliches Gebäudeenergiemodell) und dem GP-Metamodell (Abbildung 10-11) zeigt eine gute Übereinstimmung bei der Vorhersage des Wärmeenergiebedarfs im Zeitraum 2010-2016. Das GP-Metamodell bildet sowohl die Größenordnung als auch die zeitlichen Trends des Wärmeenergieverbrauchs des Gebäudes genau ab, wobei die Werte zwischen 60 kWh/m² und 100 kWh/m² für den AMY-Fall und zwischen 55 kWh/m² und 80 kWh/m² für den TRY-Fall liegen. Die perfekte Übereinstimmung zwischen den beiden Modellen, die durch überlappende Trajektorien belegt wird, bestätigt die Fähigkeit des GP-Metamodells, als effizienter Ersatz für das rechenintensivere DIBS-Modell zu dienen. Dies bestätigt die erfolgreiche Umsetzung des GP-Regressionsansatzes und seine Eignung für nachfolgende Bayes'sche Kalibrierungsschritte.

Die für Simulationen mit dem ursprünglichen DIBS-Modell benötigte Zeit beträgt 1,3 Sekunden, während das neue Metamodell dieselbe Simulation in 0,065 Sekunden durchführt, d. h. es ist mehr als 20 Mal schneller. Dieser signifikante Vorteil wird während des Kalibrierungsprozesses entscheidend, wo Iterationen über Tausende von Stichproben zahlreiche Simulationen erforderlich machen.




Abbildung 11 Ausgabe des Originalmodells (DIBS) im Vergleich zur Ausgabe des trainierten Metamodells (TRY)

8.1.4 Definition der prioritären Parameterverteilung

Der Schlüssel zu diesem konzeptionellen Rahmen ist die Festlegung von prioritären Wahrscheinlichkeitsverteilungen (wie in Tabelle 3 angegeben) für die Parameter, die ihre intrinsische Unsicherheit darstellen. Darüber hinaus wurden Vorabverteilungen für die Modelldiskrepanz und den Beobachtungsfehler festgelegt. Die Modelldiskrepanz wird durch eine Normalverteilung dargestellt, wobei die Standardabweichung durch die Standardabweichung der Vorhersage aus dem GP-Surrogatmodell bestimmt wird. Die Verteilung des Beobachtungsfehlers ist exponentiell, wobei der Median der Verteilung einen Fehler von 5 % in Bezug auf den Mittelwert der gemessenen Daten darstellt.

Tabelle 3 Variable Eingabeparameter für das Simulationstool DIBS, wobei die fünf einflussreichsten Parameter hervorgehoben sind

Eingangsparameter	Wert	Untere Schranke	Obere Schranke	Grad der Unsicherheit
Maximale Belegung	840	630	1050	Wenig Informationen
Außenwandfläche über Gelände	2471.52m ²	2224	2719	Vorhandene Informationen
Flächenverhältnis Fenster/Wand	0.567	0.51	0.62	Vorhandene Informationen
Fläche der Fassade	5712.17 m ²	5141	6283	Vorhandene Informationen
Nordfassade	2161 m ²	1081	3242	Keine Informationen
Dachfläche	3397 m ²	3057	3736	Vorhandene Informationen
Nettoraumfläche	16808 m ²	15127	18489	Vorhandene Informationen
Energiebezugsfläche	20381 m ²	18343	22419	Vorhandene Informationen
Anzahl der Geschosse ohne Keller	6	5.4	6.6	Vorhandene Informationen
Wärmerückgewinnung der RLT	0	0	0	Vorhandene Informationen
Höhe	21.03 m ²	18.93	23.13	Vorhandene Informationen
U-Wert Fenster	3,24 W/(m², K)	1.62	4.86	Wenig Informationen
U-Wert Außenwand	2,00 W/(m², K)	1	3	Wenig Informationen
U-Wert Dach	0,29 W/(m ² , K)	0.15	0.44	Wenig Informationen
U-Wert Bodenplatte	0,55 W/(m ² , K)	0.28	0.83	Wenig Informationen
Wärmekapazität	260000 J/K	110000	260000	Keine Informationen
Anlagenaufwandszahl	1.085	0.98	1.19	Keine Informationen
Transmissionsfaktor Glas	0.78	0.53	0.87	Keine Informationen

<i>Lichttransmissionsfaktor</i>	<i>1</i>	<i>0.22</i>	<i>1</i>	<i>Keine Informationen</i>
<i>Beleuchtungsichte</i>	<i>0,04 W/(m² ,lx)</i>	<i>0.03</i>	<i>0.06</i>	<i>Keine Informationen</i>
<i>Faktor der Lichtbereitstellung</i>	<i>1.09</i>	<i>0.8</i>	<i>1.5</i>	<i>Keine Informationen</i>

8.1.5 Modellkalibrierung

Der Kalibrierungsprozess, der MCMC-Methoden mit informierten Prioritätsverteilungen einsetzt, erreichte robuste Konvergenz in beiden Simulationsszenarien AMY und TRY, allerdings mit unterschiedlichen Rechenanforderungen. Im AMY-Fall wurde die Konvergenz mit 4 Ketten, 3200 Abstimmungsproben und 1600 Posterior-Ziehungen erreicht, was den vordefinierten Kriterien für die Gelman-Rubin-Statistik entspricht. Im TRY-Szenario mit ebenfalls 4 Ketten waren doppelt so viele Stichproben, 6400 Abstimmungsstichproben und 3200 Posterior Draws erforderlich, um Konvergenz zu erreichen. In beiden Fällen wurden die Gelman-Rubin-Konvergenzkriterien von $1,0 \pm 0,1$ erfüllt, was auf zuverlässige Parameterschätzungen hindeutet. Die Konvergenz wurde für beide Fälle in weniger als 5 Minuten erreicht.

Die rechte Seite von Abbildung 12 und 13 ist der Trace Plot, der veranschaulicht, wie sich die Parameterwerte im Laufe der Zeit mit dem Fortschreiten des MCMC-Samplers entwickeln und wie die akzeptierten Werte (oder Ziehungen) beginnen, die posterioren Parameterverteilungen zu formen (auf der linken Seite zu sehen). Die vier Linien stellen die vier Ketten dar, die während des Kalibrierungsprozesses initialisiert wurden. Diese Kurve dient als visuelle Kontrolle für die Konvergenz des MCMC-Samplings: Wenn die Kurve um den Modus der Verteilung oszilliert, zeigt dies an, dass das Modell eine stationäre Posteriorverteilung erreicht hat. Die vier Ketten, die von unterschiedlichen Anfangswerten ausgehen, erkunden den Parameterraum effektiv und weisen eine gute Durchmischung auf. Starke Schwankungen oder Trends in den Kurven würden auf einen Mangel an Konvergenz hindeuten, aber hier ähneln die Kurven stabilen, oszillierenden horizontalen Bändern, was auf ein effektives Sampling aus der stationären Posterior-Verteilung hindeutet. Dieses Muster ist in beiden Teststudien konsistent und spricht für ein effektives stationäres Posterior-Sampling.

Die linke Seite der Abbildung zeigt die resultierenden posterioren Wahrscheinlichkeitsverteilungen auf der Grundlage der akzeptierten Stichproben. Alle vier Ketten zeigen Korrelation in den Posterior-Wahrscheinlichkeiten, was die Stabilität der Ergebnisse bestätigt. Das AMY-Szenario weist im Vergleich zu TRY deutlich engere Konvergenzbänder auf, insbesondere bei den U-Wert-Parametern und den Schätzungen der Energieausgaben. Der Energieaufwandskoeffizient folgt einer klassischen glockenförmigen Verteilung, die im AMY-Fall um 1,1 zentriert ist, während die übrigen Parameterverteilungen zu abgestumpften Normalverteilungen tendieren.

Die posterioren Simulationsergebnisse für jedes Jahr in den Trainingsdatenreihen weisen klare Normalverteilungen auf. Obwohl dieselben Gebäude- und Messdaten verwendet werden, ergeben sich in den Fällen AMY und TRY unterschiedliche Werte in den Ergebnissen aufgrund von Unterschieden in den verwendeten Klimadaten, die zu unterschiedlichen anfänglichen Modellausgaben führen. Die posteriore Simulationsverteilung ist für das entsprechende Jahr zu sehen (siehe die Beschriftungen mit farblichen Erläuterungen für jedes Jahr). Die Mittelwerte für die Verteilung der Simulationsergebnisse stimmen mit den Messwerten in den Abbildungen 4-5 überein. Ein direkter Vergleich zwischen den Szenarien erfordert eine sorgfältige Betrachtung ihrer jeweiligen Ausgangsbedingungen und Klimadatencharakteristika, da die absoluten Werte relativ zu ihren spezifischen Eingabedatensätzen sind. Dieser Vergleich erfordert eine detaillierte Untersuchung, um die Auswirkungen auf die Modellzuverlässigkeit und die Vorhersagegenauigkeit zu verstehen. Dieser Aspekt wird im folgenden Abschnitt näher untersucht.




Abbildung 12 Ergebnisse der progressiven Kalibrierung: Posteriore Wahrscheinlichkeiten und Spuren der akzeptierten Ziehungen (AMY)




Abbildung 13 Ergebnisse der progressiven Kalibrierung: Posteriore Wahrscheinlichkeiten und Spuren der akzeptierten Ziehungen (TRY)

Abbildung 14-15 zeigen einen Vergleich zwischen den Modellparameterwerten vor der Kalibrierung und den daraus resultierenden Werten nach der Kalibrierung. Die Wahrscheinlichkeitsverteilungen zeigen eine deutliche Verschiebung der Mittelwerte, was darauf hindeutet, dass das Modell mit aktualisierten Parameterschätzungen kalibriert wurde. Außerdem spiegeln die verringerten Standardabweichungen ein größeres Vertrauen in die posterioren Schätzungen im Vergleich zu den ursprünglichen Annahmen wider. Dies entspricht den erwarteten Ergebnissen, da die Parameterschätzungen während des Kalibrierungsprozesses iterativ anhand von Beobachtungsdaten verfeinert werden und das Vertrauen größer wird.




Abbildung 14 Prior- und Posterior-Wahrscheinlichkeitsverteilungen der Parameter (AMY)




Abbildung 15 Prior- und Posterior-Wahrscheinlichkeitsverteilungen der Parameter (TRY)

Die Prior- und Posteriorverteilungen für die Fälle AMY und TRY zeigen eine erhebliche Verfeinerung der Parameter durch die Bayes'sche Kalibrierung. Die Analyse zeigt signifikante Verschiebungen in den Parameterverteilungen, was auf effektives Lernen aus dem Kalibrierungsprozess hinweist.

In beiden Fällen weisen die U-Wert-Parameter (für Fenster und Außenwände) bemerkenswerte Verschiebungen hin zu höheren Werten in ihren Posterior-Verteilungen auf, begleitet von einer geringeren Unsicherheit im Vergleich zu ihren Priors. Bei den beleuchtungsbezogenen Parametern (Beleuchtungsleistungsdichte und charakteristischer Lampenfaktor) verschieben sich die Posteriorwerte in beiden Fällen in ähnlicher Weise zu niedrigeren Werten, wobei die Streuung wesentlich geringer ist als bei den Priors. Diese Konsistenz zwischen AMY- und TRY-Szenarien unterstreicht die Robustheit des Kalibrierungsprozesses.

Der Hauptunterschied zwischen den beiden Fällen zeigt sich beim Heizeffizienz. Im AMY-Fall ist die posteriore Verteilung um den Wert 1,1 zentriert und weist breitere Unsicherheitsbänder auf. Im Gegensatz dazu verschiebt die TRY-Kalibrierung diesen Parameter zu deutlich höheren Werten (schiefe Verteilung mit höheren Mittelwerten), was darauf hindeutet, dass das Modell möglicherweise auf diese Weise angepasst werden muss, um die gemessenen Daten besser zu erfüllen, was den Einfluss der unterschiedlichen Klimadaten im TRY-Szenario widerspiegelt.

Insgesamt zeigen die Formen der posterioren Verteilung einen wichtigen Unterschied: Der AMY-Fall zeigt im Allgemeinen etwas breitere Verteilungen als TRY, insbesondere für den Heizkoeffizienten und die U-Werte. Dies deutet darauf hin, dass beide Datensätze zwar ähnliche kalibrierte Parameter ergeben, die AMY-basierte Kalibrierung jedoch eine größere Parameterunsicherheit berücksichtigt, was wahrscheinlich auf die größere Variabilität der tatsächlichen Wetterbedingungen im Vergleich zu den standardisierten TRY-Daten zurückzuführen ist. Es sollte auch angemerkt werden, dass die Kohärenz zwischen AMY- und TRY-Szenarien, die trotz unterschiedlicher Eingangsbedingungen der Klimadaten ähnliche Richtungsverschiebungen in den Parameterverteilungen zeigen, ein starker Beweis für die Robustheit und Zuverlässigkeit der Kalibrierungsmethode ist.

8.1.6 Kalibriertes Modell

Das kalibrierte Modell stellt die Integration von Posterior-Parameterverteilungen in das ursprüngliche Modell dar und wandelt Einzelwertvorhersagen in probabilistische Ausgaben um, die von Natur aus Parameterunsicherheiten erfassen. Da die posterioren Parameterwerte durch eine Wahrscheinlichkeitsverteilung gekennzeichnet sind, spiegeln die kalibrierten Modellausgaben diese Verteilung ebenfalls wider. Folglich produziert das kalibrierte Modell keinen einzelnen Ausgabewert, sondern liefert eine Verteilung, die die inhärenten Unsicherheiten des Modells berücksichtigt. Diese Ergebnisse werden mit Konfidenzintervallen dargestellt und bieten ein quantifizierbares Maß für die Zuverlässigkeit des kalibrierten Modells.

In Abbildung 16-17 sind die für die Kalibrierung verwendeten Trainingsdaten grau hinterlegt, wie bereits in Abbildung 12-13 unter Simulationsergebnisse zu sehen, während der verbleibende Teil der Zeitreihe die Modellvorhersagen darstellt. Die Werte der Eingangsparameter, die aus den posterioren Verteilungen entnommen wurden, führen zu Simulationsergebnissen, die gut mit den beobachteten Daten übereinstimmen (in schwarz), im Gegensatz zu den Simulationsergebnissen vor der Kalibrierung (in rot). Da der Kalibrierungsprozess jedoch durch die Definitionen der Prioritätswahrscheinlichkeit der Parameter eingeschränkt ist, stimmt er möglicherweise nicht vollständig mit den beobachteten Daten überein. Ein weiterer Grund ist, dass verschiedene Parameterwerte gleichzeitig zufriedenstellende Antworten für die verschiedenen Jahre liefern. Der Kalibrierungsprozess muss daher die Parameterwerte finden, die in den meisten Fällen gleichzeitig die höchste Zufriedenheit ergeben. Dies kann in manchen Fällen zu kleinen Abweichungen für einige Jahre führen. Die Ergebnisse veranschaulichen ein Gleichgewicht zwischen den Parameterannahmen und den beobachteten Daten, und diese Vergleiche dienen als Mittel zur Bewertung der Leistung des kalibrierten Modells.

Darüber hinaus ergeben sich aus den Klimadaten auch gewisse Einschränkungen; das Modell kann für ein Jahr eine hervorragende Anpassung erreichen, während es für ein anderes Jahr schlecht abschneidet. Daher werden während des Kalibrierungsprozesses die kalibrierten Ergebnisse so ausgewählt, dass sie die Kalibrierungskriterien für alle Jahre gleichzeitig erfüllen.




Abbildung 16 Kalibrierte Modellergebnisse als Posterior-Wahrscheinlichkeitsverteilungen, im Verhältnis zu den ursprünglichen Modellergebnissen vor der Kalibrierung (rot) und den entsprechenden Messdaten (AMY)




Abbildung 17 Kalibrierte Modellergebnisse als Posterior-Wahrscheinlichkeitsverteilungen, im Verhältnis zu den ursprünglichen Modellergebnissen vor der Kalibrierung (rot) und den entsprechenden Messdaten (TRY)

Bewertung der Kalibrierungsqualität:

Die Bewertung der Kalibrierungsqualität auf der Grundlage der Kriterien der ASHRAE-Richtlinie 14 (CV(RMSE) und R^2) zeigt, dass die Modellkalibrierung sowohl für den AMY- als auch für den TRY-Fall bemerkenswert erfolgreich ist, wobei das TRY-Szenario insgesamt bessere Leistungskennzahlen aufweist.

Für den AMY-Fall bestätigen die Kalibrierungsmetriken eine gute Leistung gemäß den strengen jährlichen Kriterien von ASHRAE. Der CV(RMSE) und R^2 der leistungsstärksten Simulation erfüllen den empfohlenen Schwellenwert von 5 % bzw. das Kriterium von $R^2 > 0,75$. Darüber hinaus deutet die relativ geringe Standardabweichung beim CV(RMSE) (1,10 %) auf eine konsistente Modellleistung bei verschiedenen Parameterkombinationen hin.

Der TRY-Fall weist eine wesentlich bessere Übereinstimmung mit den ASHRAE-Richtlinien auf. Der mittlere CV(RMSE) von 3,29 % ($\pm 0,57\%$) erfüllt problemlos das 5%-Kriterium, wobei der beste Simulationsfall 2,93 % erreicht. Die R^2 -Werte sind besonders stark, was auf eine gute Kalibrierung hindeutet, mit einem mittleren R^2 von 0,891 ($\pm 0,053$) und dem besten Simulations- R^2 von 0,917, der deutlich über dem Schwellenwert von 0,75 liegt.

Die bessere Leistung des Kalibrierungsframeworks im TRY-Fall deutet darauf hin, dass das kalibrierte Modell mit standardisierten Wetterdaten für dieses spezifische Gebäude zuverlässiger arbeitet, obwohl beide Fälle die Wirksamkeit des Bayes'schen Kalibrierungsansatzes bei der Erreichung der jährlichen ASHRAE-Kalibrierungsstandards demonstrieren.

8.1.7 Vorhersage-Szenario

Es wurde ein Vorhersageszenario erstellt und simuliert, um die potenziellen Auswirkungen einer Sanierungsmaßnahme wie dem Austausch von Fenstern mit niedrigeren U-Werten aufzuzeigen, die sich auf der Grundlage der vorangegangenen Sensitivitätsanalyse als der einflussreichste Parameter herausstellte. Die U-Werte wurden vom posterioren Mittelwert von 4,1 W/(m² ,K) auf 1,3 W/(m² ,K) angepasst, was den Sanierungsstandards für Nichtwohngebäude in Deutschland gemäß der GEG-Verordnung (GEG, 2020) entspricht. Das kalibrierte Modell wurde verwendet, um die Heizenergieeinsparungen und die Reduzierung des Treibhauspotenzials abzuschätzen, wie in Abbildung 18 dargestellt. Die Ergebnisse des Vorhersageszenarios zeigen, dass die vorgeschlagene Sanierungsmaßnahme Energieeinsparungen zwischen 28 und 51 kWh/m² und eine Reduzierung des Treibhauspotenzials zwischen 6 und 11 kg/m² erzielen könnte, mit einem 90%-Konfidenzintervall. Diese Ergebnisse dienen als solide Grundlage für die Beurteilung der wirtschaftlichen Rentabilität der Sanierungsmaßnahme und unterstützen die Entscheidungsfindung für Investitionen in nachhaltige Gebäude. Im Vergleich zu einer deterministischen Einzelwertausgabe erhöht die Einbeziehung der Unsicherheitsanalyse die Zuverlässigkeit dieser Bewertungen und bietet eine umfassende Grundlage für fundierte Entscheidungen.




Abbildung 18 Prognoseszenario für das Jahr 2017. Einsparungen beim Wärmeenergieverbrauch und bei Treibhausgasemissionen nach dem kalibrierten Modell (AMY) mit zugewiesenen 90 % - Vertrauensintervallen

8.2 Fallstudie 2

Das implementierte Open-Source-Bayesian-Kalibrierungssystem wurde in einer zweiten Fallstudie validiert, die speziell entwickelt wurde, um eine Vielseitigkeit in verschiedenen zeitlichen Auflösungen zu testen. Unter Verwendung von Gebäudeenergieverbrauchsdaten aus dem Portfolio *der BIM* geht diese Fallstudie über jährliche Aggregationen hinaus und umfasst wöchentliche und monatliche zeitliche Auflösungen. Diese Fallstudie wurde strategisch aufgrund der Verfügbarkeit umfassender zeitlicher Auflösungen (wöchentlich, monatlich und jährlich) ausgewählt, um eine Bewertung der Robustheit des Frameworks über mehrere Zeitskalen hinweg zu ermöglichen. Die Zeitspanne der verfügbaren Messdaten variierte für jede Auflösung und erforderte eine Datenverarbeitung, um kontinuierliche Zeitreihen zu identifizieren, die für die Demonstration des Frameworks geeignet sind.

Die Untersuchung zielt darauf ab, die Vielseitigkeit des Frameworks bei der Kalibrierung von DIBS-Gebäudeenergiemodellen für Vorhersagen des Heizenergiebedarfs in verschiedenen zeitlichen Auflösungen unter Verwendung der Klimadaten des tatsächlichen meteorologischen Jahres zu demonstrieren. Dieser Multi-Resolution-Validierungsansatz liefert entscheidende Einblicke in die Anpassungsfähigkeit und Zuverlässigkeit der Kalibrierungsmethodik, insbesondere bei der Anwendung auf reale Gebäudeenergiemanagement-Szenarien. Die erfolgreiche Automatisierung und Validierung über mehrere Zeitskalen hinweg zeigt das Potenzial des Frameworks für eine breitere Implementierung in praktischen Anwendungen, insbesondere in Szenarien, in denen eine hochauflösende zeitliche Analyse für betriebliche Entscheidungen und die Bewertung von Nachrüstungen entscheidend ist.

8.2.1 Gebäudeenergiemodell

Abbildung 19-21 zeigt den Vergleich zwischen dem gemessenen und dem simulierten Wärmeenergieverbrauch für das untersuchte Gebäude, dargestellt in wöchentlicher, monatlicher und jährlicher Zeitauflösung. Die verschiedenen zeitlichen Auflösungen offenbaren deutliche Muster und Diskrepanzen, was die Notwendigkeit einer Modellkalibrierung verdeutlicht.




Abbildung 19 Simulationsergebnisse von DIBS vor der Kalibrierung im Vergleich zu den gemessenen Daten in monatlicher Auflösung

Bei der wöchentlichen Auflösung sind hochfrequente Schwankungen mit beträchtlichen Diskrepanzen zwischen gemessenen und simulierten Werten zu beobachten, insbesondere in Spitzenzeiten (z. B. 2019-

01-27), wo die Simulation den Verbrauch um etwa 1 kWh/m² überschätzt. Die kurzfristige Dynamik und die schnellen Schwankungen deuten darauf hin, dass das unkalibrierte Modell Schwierigkeiten hat, wöchentliche Betriebsmuster und wetterbedingte Schwankungen genau zu erfassen.




Abbildung 20 Simulationsergebnisse von DIBS vor der Kalibrierung im Vergleich zu den gemessenen Daten in monatlicher Auflösung.

Der Vergleich des monatlichen Heizenergieverbrauchs zwischen der gemessenen und der nicht kalibrierten Modellvorhersage zeigt klare saisonale Muster mit Spitzenwerten im Winter (15-17 kWh/m²) und Tiefpunkten im Sommer (etwa 0-2 kWh/m²). Während der allgemeine saisonale Trend erfasst wird, sind systematische Diskrepanzen bei den Bedarfsspitzen im Winter und in den Sommermonaten zu beobachten. Das nicht kalibrierte Modell neigt dazu, den Spitzenverbrauch im Winter zu überschätzen und die anderen Jahreszeiten zu unterschätzen.




Abbildung 21 Simulationsergebnisse von DIBS vor der Kalibrierung im Vergleich zu den gemessenen Daten mit jährlicher Auflösung.

Andererseits zeigt die jährliche Vorhersage eine große Diskrepanz zum gemessenen Wärmeenergiebedarf. Die konsistenten Abweichungsmuster über mehrere Jahre hinweg deuten auf strukturelle Modellunsicherheiten hin, die über längere Zeiträume bestehen bleiben, insbesondere bei der Erfassung der jährlichen Schwankungen des Wärmebedarfs.

Die beobachteten Diskrepanzen zwischen gemessenen und simulierten Daten in verschiedenen Auflösungen unterstreichen den dringenden Bedarf an einer Modellkalibrierung, um systematische Verzerrungen über zeitliche Skalen hinweg zu beheben und die Fähigkeit des Modells zu verbessern, sowohl die vorübergehende Dynamik als auch saisonale Muster zu erfassen. Die Kalibrierung ist unerlässlich, um die Vorhersagekraft des Modells über verschiedene betriebliche Planungshorizonte hinweg zu verbessern und gleichzeitig gebäudespezifische Merkmale und betriebliche Muster zu berücksichtigen, die von den Standardparametern nicht erfasst werden. Dieser umfassende Kalibrierungsansatz würde dazu beitragen, den Nutzen des Modells als zuverlässiges Instrument für die Vorhersage des Energiebedarfs und die Optimierung der Gebäudeleistung zu erweitern.

8.2.2 Sensitivitätsanalyse

Für 21 Parameter des Gebäudeenergiemodells wurde eine systematische Sensitivitätsanalyse durchgeführt, um die einflussreichsten Faktoren für die Bayes'sche Kalibrierung zu ermitteln. Unter Verwendung der Sobol-Methode wurde der Stichprobenumfang systematisch von 2^4 auf 2^8 (704 bis 2816 Parameterkombinationen) entsprechend der für die Sobol-Analyse erforderlichen $N \times (2D+2)$ -Formulierung. Der Total Sensitivity Index erreichte Konvergenz bei $N=64$ (2816 Stichproben) für alle Fälle und identifizierte fünf dominante Parameter mit stabilen Rankings in 5, 25 und 57 Minuten Rechenzeit für die jeweiligen Zeitaufösungen wöchentlich, monatlich und jährlich. Diese fünf einflussreichsten Parameter wurden anschließend für die Multi-Resolution-Kalibrierung über wöchentliche, monatliche und jährliche Zeitskalen verwendet, um einen effizienten und dennoch umfassenden Kalibrierungsprozess zu gewährleisten, der ein Gleichgewicht zwischen Recheneffizienz und Bedeutung der Parameter herstellt.




Abbildung 22 Rangfolge der Parameter auf der Grundlage einer globalen Sensitivitätsanalyse, berechnet mit wöchentlicher Ausgabeauflösung




Abbildung 23 Rangfolge der Parameter auf der Grundlage einer globalen Sensitivitätsanalyse, berechnet mit monatlicher Ausgabeauflösung




Abbildung 24 Rangfolge der Parameter auf der Grundlage einer globalen Sensitivitätsanalyse, berechnet mit jährlicher Ausgabeauflösung

Die Sobol-Sensitivitätsanalyse, die für wöchentliche, monatliche und jährliche Auflösungen durchgeführt wurde, identifizierte konsistent die fünf wichtigsten Parameter, die sich auf die Gesamtenergieeffizienz des Gebäudes auswirken, wie in den Abbildungen 22-24 zu sehen ist. Bemerkenswert ist, dass die Parameterhierarchie über die zeitlichen Auflösungen hinweg konsistent blieb, mit minimalen Rangeschwankungen unter den fünf wichtigsten Parametern, was ihre Auswahl für die nachfolgende Ersatzmodellierung des ursprünglichen Simulators und die Bayes'sche Kalibrierung bestätigt. Die einflussreichsten Parameter sind in allen Fällen der U-Wert der Außenwände, der charakteristische Lampenfaktor, die Energiebezugsfläche, der Energieaufwandsfaktor und die Leistungsdichte der Beleuchtung. Diese identifizierten dominanten Parameter werden anschließend zur Entwicklung eines Gauß'schen Prozess-Surrogatmodells für eine effiziente Bayes'sche Kalibrierung herangezogen.

8.2.3 Gauß'sches Prozess-Surrogatmodell

Das Gauß-Prozess-Metamodell wurde unter Verwendung der zuvor ermittelten Parameterintervalle entwickelt, wobei eine 75:25-Train-Test-Split-Strategie angewandt wurde. Als Konvergenzkriterien für das Modell wurden $R^2 > 0,99$ und $\text{NRMSE} < 0,07\%$ festgelegt, um die Genauigkeit des Surrogatmodells zu gewährleisten. Das Training des Metamodells begann mit einer anfänglichen Stichprobengröße von 30, wobei je nach zeitlicher Auflösung unterschiedliche Inkrementierungsstrategien angewandt wurden: 2-Proben-Inkmente für jährliche und wöchentliche Daten und 10-Proben-Inkmente für monatliche Daten. Dieser Ansatz für die Stichprobenziehung wurde als Reaktion auf die Beobachtung gewählt, dass Daten mit höherer zeitlicher Auflösung, die eine größere Anzahl von Ausgängen und größere Schwankungen aufweisen (wie in Abbildung 20 im Gegensatz zu Abbildung 19 und 21 gezeigt), in der Regel größere Stichprobengrößen für eine genaue Darstellung erfordern.




Abbildung 25 Gaußsche Prozessregression zur Erstellung des Metamodells für die zeitliche Auflösung der wöchentlichen Messdaten




Abbildung 26 Gaußsche Prozessregression zur Erstellung des Metamodells für die zeitliche Auflösung der monatlichen Messdaten




Abbildung 27 Gaußsche Prozessregression, die zur Erstellung des Metamodells für die zeitliche Auflösung der jährlichen Messdaten verwendet wurde

Die Konvergenzmuster, die in den Abbildungen 25-27 durch abnehmende Normalisierte RMSE- und steigende R^2 -Werte für alle Auflösungen gekennzeichnet sind, bestätigen die Robustheit des Surrogatmodellierungsansatzes unter Beibehaltung der vordefinierten Genauigkeitskriterien. Bei der wöchentlichen Auflösung trat die Konvergenz bei 64 Proben auf (NRMSE: 0,067 %, R^2 -Wert: 0,9999), bei der monatlichen Auflösung bei 380 Proben (NRMSE: 0,072 %, R^2 -Wert: 0,9964) und bei der jährlichen Auflösung bei 58 Proben (NRMSE: 0,060 %, R^2 -Wert: 1,000). Bemerkenswert ist, dass bei allen zeitlichen Auflösungen derselbe Rational-Quadratische Kernel ($1 \times 2 \times \text{RationalQuadratisch}$ ($\alpha=1$, $\text{length_scale}=1$)) verwendet wurde, was auf ein konsistentes Modellverhalten über alle Zeitskalen hinweg schließen lässt. Die für das Finden und Trainieren des optimalen Metamodells erforderliche Rechenzeit betrug 5 Minuten für die wöchentliche Auflösung, 198 Minuten für die monatliche Auflösung und 13 Minuten für die jährliche Auflösung.

Die Validierungsergebnisse des trainierten Metamodells sind in Abbildung 28-30 dargestellt, wo die Vorhersagen des Metamodells gegen das ursprüngliche DIBS-Gebäudeenergiemodell aufgetragen sind.




Abbildung 28 Ursprüngliche Modellausgabe (DIBS) im Vergleich zur Ausgabe des trainierten Metamodells für eine wöchentliche Zeitauflösung




Abbildung 29 Ursprüngliche Modellausgabe (DIBS) im Vergleich zur Ausgabe des trainierten Metamodells für eine monatliche Zeitauflösung




Abbildung 30 Ursprüngliche Modellausgabe (DIBS) im Vergleich zur Ausgabe des trainierten Metamodells für eine jährliche Zeitauflösung

Der Vergleich der Vorhersage des Heizenergiebedarfs zwischen der DIBS und dem Gauß-Prozess-Metamodell zeigt eine gute Übereinstimmung über alle zeitlichen Auflösungen für die spezifische Fallstudie. Die wöchentliche Auflösung erfasst die kurzfristigen Schwankungen genau und zeigt detaillierte Übergänge im Wärmebedarf von 0,5 bis 4,5 kWh/m². Die monatlichen Vorhersagen erfassen effektiv saisonale Muster mit einem Spitzenbedarf von ca. 18 kWh/m² während der Wintermonate und einem minimalen Verbrauch während der Sommerperioden. Die jährliche Aggregation zeigt einen langfristigen Trend mit einem Spitzenverbrauch von 82 kWh/m² im Jahr 2016, gefolgt von einem allmählichen Rückgang bis 2018. Die Überschneidung zwischen den Vorhersagen der DIBS und des Metamodells über alle Zeitskalen hinweg bestätigt die Fähigkeit des Ersatzmodells, das Verhalten des ursprünglichen Modells zu replizieren und gleichzeitig die Recheneffizienz zu erhalten. Diese Mehrfachauflösungsgenauigkeit bestätigt die Zuverlässigkeit des Metamodells für nachfolgende Bayes'sche Kalibrierungsprozesse.

8.2.4 Definition der prioritären Parameterverteilung

Das Kalibrierungsframework für diese zweite Fallstudie verwendet in ähnlicher Weise probabilistische Verteilungen zur Quantifizierung der Parameterunsicherheit. Für die fünf identifizierten einflussreichen Parameter wurden auf der Grundlage von Expertenwissen und Gebäudespezifikationen Prioritätsverteilungen erstellt (siehe Tabelle 4). Die Modelldiskrepanz wird durch eine Normalverteilung charakterisiert, deren Standardabweichung aus der Vorhersageunsicherheit des GP-Surrogatmodells abgeleitet wird. Der Beobachtungsfehler wird mit einer Exponentialverteilung modelliert, die so kalibriert ist, dass sie einen Fehler von 5 % relativ zum arithmetischen Mittel der gemessenen Wärmeenergieverbrauchsdaten des untersuchten Gebäudes darstellt. Dieser probabilistische Ansatz ermöglicht eine umfassende Quantifizierung der Unsicherheit in wöchentlicher, monatlicher und jährlicher zeitlicher Auflösung und bietet eine solide Grundlage für den Bayes'schen Kalibrierungsprozess.

Tabelle 4 Variable Eingabeparameter für das Simulationstool DIBS, wobei die fünf einflussreichsten Parameter hervorgehoben sind

<i>Eingangsparameter</i>	<i>Wert</i>	<i>Untere Schranke</i>	<i>Obere Schranke</i>	<i>Grad der Unsicherheit</i>
<i>Maximale Belegung</i>	77	57.75	96.25	<i>Wenig Informationen</i>
<i>Außenwandfläche über Gelände</i>	1088.23m ²	979.407	1197.053	<i>Vorhandene Informationen</i>
<i>Flächenverhältnis Fenster/Wand</i>	0.063437	0.0570933	0.0697807	<i>Vorhandene Informationen</i>
<i>Fläche der Fassade</i>	1161.94 m ²	1045.746	1278.134	<i>Vorhandene Informationen</i>
<i>Nordfassade</i>	464.231 m ²	232.1155	696.3465	<i>Keine Informationen</i>
<i>Dachfläche</i>	456.34 m ²	410.706	501.974	<i>Vorhandene Informationen</i>
<i>Nettoraumfläche</i>	1533.2m ²	1642.824	2007.896	<i>Vorhandene Informationen</i>
<i>Energiebezugsfläche</i>	1825.36m ²	18343	22419	<i>Vorhandene Informationen</i>
<i>Anzahl der Geschosse ohne Keller</i>	4	3.6	4.4	<i>Vorhandene Informationen</i>
<i>Wärmerückgewinnung der RLT</i>	0	0	0	<i>Vorhandene Informationen</i>
<i>Höhe</i>	10.9 m ²	9.81	11.99	<i>Vorhandene Informationen</i>
<i>U-Wert Fenster</i>	1,35 W/m ² , K	0.675	2.025	<i>Wenig Informationen</i>
<i>U-Wert Außenwand</i>	0,5 W/m ² , K	0.25	0.75	<i>Wenig Informationen</i>
<i>U-Wert Dach</i>	0,25 W/m ² , K	0.125	0.375	<i>Wenig Informationen</i>
<i>U-Wert Bodenplatte</i>	0,4 W/m ² , K	0.2	0.6	<i>Wenig Informationen</i>
<i>Wärmekapazität</i>	260000 J/K	110000	260000	<i>Keine Informationen</i>
<i>Anlagenaufwandszahl</i>	1.085	0.98	1.19	<i>Keine Informationen</i>
<i>Transmissionsfaktor Glas</i>	0.78	0.53	0.87	<i>Keine Informationen</i>
<i>Lichttransmissionsfaktor</i>	1	0.22	1	<i>Keine Informationen</i>
<i>Beleuchtungsichte</i>	0,03 W/m ² , lx	0.024	0.039	<i>Keine Informationen</i>
<i>Faktor der Lichtbereitstellung</i>	1.09	0.8	1.5	<i>Keine Informationen</i>

8.2.5 Modellkalibrierung

Die Implementierung des MCMC-Kalibrierungsverfahrens mit spezifizierten Prioritätsverteilungen zeigte robuste Konvergenz für wöchentliche, monatliche und jährliche Auflösungen. Bei allen zeitlichen Auflösungen wurde Konvergenz mit 800 Abstimmungsproben und 400 Posterior Draws in jeder der 4 Ketten erreicht, wobei die vordefinierten Kriterien für die Gelman-Rubin-Statistik erfüllt wurden. Die Berechnungszeit für die wöchentliche, monatliche und jährliche Kalibrierung betrug 1, 2 bzw. 1 Minute. Die Trace-Plots (rechts) zeigen, wie sich die Parameterwerte während des MCMC-Samplings entwickelt haben, wobei vier unabhängige Ketten den Parameterraum ausgehend von verschiedenen Anfangswerten effektiv erkundet haben. Wie aus den Abbildungen 31-33 ersichtlich ist, folgt die Modelldiskrepanz einer um Null zentrierten Normalverteilung mit konsistenter Varianz, was auf eine angemessene Modellierung der Fehlerstruktur hinweist. Die Trace-Plots weisen für jede zeitliche Auflösung unterschiedliche Merkmale auf:

Wöchentliche Auflösung:

- Die Parameterverteilungen zeigen eine deutliche Konvergenz mit einem stabilen Posterior-Sampling, das den Bereich der Parameterwahrscheinlichkeit auslotet und innerhalb der definierten Posterior-Wahrscheinlichkeitsverteilung über alle Ketten hinweg oszilliert.
- Modelldiskrepanz und Beobachtungsfehler weisen über die Stichproben hinweg eine einheitliche Größenordnung auf
- Die Posteriorverteilungen der in Abbildung 31 dargestellten Simulationsergebnisse zeigen eine erfolgreiche Korrelation mit den zuvor in Abbildung 19 dargestellten Messdaten.

Monatliche Entschließung:

- Auch in diesem Fall zeigen die Kurvenplots deutlich eine Oszillation innerhalb der Posteriorwahrscheinlichkeiten für die Parameter, was auf eine stabile Konvergenz hinweist.
- In ähnlicher Weise spiegeln die posterioren Simulationsergebnisse der monatlichen Kalibrierung die monatlichen Messdaten genau wider. Dies kann durch einen Vergleich zwischen Abbildung 20 mit den Messdaten und Abbildung 32 mit der Posteriorverteilung der Simulationsergebnisse bestätigt werden. Beide schwanken zwischen 0 und 20 kWh/m².
- Die Wahrscheinlichkeitswerte der Posterior-Parameter sind mit denen vergleichbar, die bei der Kalibrierung mit wöchentlicher Zeitauflösung ermittelt wurden. Der größte Unterschied ist beim U-Wert der Außenwände zu beobachten, der bei der monatlichen Kalibrierung höher ist.

Jährlicher Vorsatz:

- Die Parameterverteilungen sind in diesem Fall von allen Auflösungen am stabilsten und weisen minimale Unterschiede zwischen den verschiedenen Ketten auf.
- Ähnlich wie in den anderen Fällen spiegeln die posterioren Simulationsergebnisse die für die Kalibrierung verwendeten jährlichen Messdaten genau wider. Dies wird durch einen Vergleich mit Abbildung 21 bestätigt, in der die jährlichen Messwerte zwischen 70 und 100 kWh/m² liegen, was gut mit den Ergebnissen der posterioren Simulation in Abbildung 32 übereinstimmt.

Die linken Felder zeigen die sich ergebenden Posterior-Wahrscheinlichkeitsverteilungen auf der Grundlage der akzeptierten Stichproben. Alle vier Ketten zeigen eine Korrelation der posterioren Wahrscheinlichkeiten über die zeitlichen Skalen hinweg, was die Stabilität der Ergebnisse bestätigt. Während die wöchentliche Auflösung breitere Verteilungen zeigt, die eine höhere zeitliche Variabilität widerspiegeln, zeigen die monatlichen und jährlichen Auflösungen zunehmend konzentriertere posteriore Verteilungen.

Der Vergleich der zeitlichen Auflösung zeigt eine zunehmende Stabilität von der wöchentlichen zur jährlichen Skala. Die wöchentliche Auflösung zeigt dynamischere Parametervariationen unter Beibehaltung der Konvergenz, die monatliche Auflösung zeigt eine geringere Parametervariabilität mit einer ausgeprägteren Stabilität bei der Abtastung der Heizkoeffizienten und die jährliche Auflösung weist die stabilsten Parameterverteilungen mit minimalen Problemen der Kettenvermischung auf. Der Beobachtungsfehler bleibt über alle zeitlichen Skalen hinweg konsistent und die Simulationsergebnisse zeigen eine klare Trennung zwischen verschiedenen Parameterkombinationen, was die Zuverlässigkeit der kalibrierten Parameterschätzungen weiter bestätigt. Die konsistente Leistung des Modells über alle zeitlichen Auflösungen hinweg, die durch stabile MCMC-Ketten und wohldefinierte Posterior-Verteilungen belegt wird, bestätigt die Effizienz des Kalibrierungsframeworks für dieses Gebäudeenergiemodell.




Abbildung 31 Ergebnisse der progressiven Kalibrierung: Posteriore Wahrscheinlichkeiten und Spuren der akzeptierten Ziehungen für die wöchentliche Zeitauflösung




Abbildung 32 Ergebnisse der progressiven Kalibrierung: Posteriorwahrscheinlichkeiten und Spuren der akzeptierten Ziehungen für die monatliche Zeitauflösung




Abbildung 33 Ergebnisse der progressiven Kalibrierung: Posteriore Wahrscheinlichkeiten und Spuren der akzeptierten Ziehungen für die jährliche Zeitauflösung

Die Ergebnisse der Bayes'schen Kalibrierung zeigen unterschiedliche Muster der Parameterverfeinerung in verschiedenen zeitlichen Auflösungen für das Gebäude. In der wöchentlichen Auflösung zeigt der U-Wert der Außenwände eine scharf definierte Posterior-Verteilung, die bei 0,6 W/m²K zentriert ist, während der charakteristische Lampenfaktor eine konzentrierte Verschiebung zu niedrigeren Werten (0,8-1,0) aufweist. Die Energiebezugsfläche konvergiert bei 1700-1800 m², und der Heizkoeffizient zeigt eine enge posteriore Verteilung bei 0,92. Die Beleuchtungsleistungsdichte zeigt eine deutliche Verschiebung in Richtung 0,025-0,030 W/m².

Monatliche und jährliche Auflösungen zeigen ähnliche Verfeinerungsmuster, jedoch mit deutlich unterschiedlichen Unsicherheitsbereichen. Die jährliche Kalibrierung zeigt die ausgeprägteste Parameterverfeinerung, insbesondere für den U-Wert der Außenwände (Posterior-Mittelwert ~0,7 W/m²K) und den Heizkoeffizienten (Posterior-Mittelwert ~1,05). Diese zeitliche Variation in den Parameterverteilungen deutet darauf hin, dass das Kalibrierungsframework sowohl die kurzfristige Dynamik als auch die langfristigen Eigenschaften der Gebäudeleistung effektiv erfasst und dabei die physikalische Konsistenz über verschiedene Zeitskalen hinweg beibehält.




Abbildung 34 Prior- und Posterior-Parameter-Wahrscheinlichkeitsverteilungen (wöchentlich)




Abbildung 35 Prior- und Posterior-Wahrscheinlichkeitsverteilungen der Parameter (monatlich)




Abbildung 36 Prior- und Posterior-Parameter-Wahrscheinlichkeitsverteilungen (jährlich)

Der Vergleich der Prior- und Posterior-Verteilungen über die verschiedenen zeitlichen Auflösungen hinweg zeigt außerdem wichtige unterschiedliche Kalibrierungsmerkmale. Die wöchentliche Auflösung zeigt die breitesten Posterior-Verteilungen, besonders deutlich bei den Parametern U-Wert und Heizkoeffizient, was die inhärente Variabilität der kurzfristigen Energieverbrauchsmuster widerspiegelt. Die monatliche Auflösung zeigt eine mittlere Verfeinerung, wobei die Posteriorverteilungen deutlichere Spitzen aufweisen, aber eine moderate Streuung beibehalten, insbesondere beim Heizkoeffizienten, der um 0,95 liegt. Die jährliche Auflösung weist die entscheidendste Parameterverfeinerung auf, die durch die schärfsten Posteriorverteilungen und die ausgeprägtesten Verschiebungen gegenüber den vorherigen Werten gekennzeichnet ist, was insbesondere beim U-Wert-Parameter, der definitiv bei $0,7 \text{ W}/(\text{m}^2\text{K})$ seinen Höhepunkt erreicht, und beim Heizkoeffizienten, der Werte zwischen 1,05 und 1,10 stark bevorzugt, deutlich wird. Diese fortschreitende Verschärfung der Posteriorverteilungen von wöchentlicher zu jährlicher Auflösung deutet darauf hin, dass längere Zeitskalen robustere Parameterschätzungen liefern, indem sie kurzfristige Schwankungen ausgleichen, wenn auch möglicherweise um den Preis, dass Einblicke in die saisonale und betriebliche Dynamik verloren gehen, die bei feineren Zeitskalen erfasst werden.

8.2.6 Kalibriertes Modell

Die Leistungsbewertung des kalibrierten Gebäudeenergiemodells für die jährliche zeitliche Auflösung zeigt eine deutliche Verbesserung der Vorhersagegenauigkeit. Abbildung 37 zeigt den Vergleich

zwischen gemessenen Daten (schwarze Linie), nicht kalibrierten DIBS-Modellvorhersagen (rote Linie) und den kalibrierten Modellergebnissen (blaue Verteilungen) für das Gebäude im Zeitraum 2014-2019. Das Trainingszeitintervall ist schattiert, während das verbleibende Intervall die vorhergesagte Zeitreihe darstellt.

Für die jährliche Auflösung verbessert die Kalibrierung die unkalibrierten DIBS-Vorhersagen erheblich, die den Verbrauch anfänglich um 20-25 kWh/m² unterschätzten. Das kalibrierte Modell erfasst erfolgreich den Gesamttrend von 2014 bis 2019, insbesondere den Spitzenverbrauch um 100 kWh/m² im Jahr 2016 und den anschließenden Rückgang im Jahr 2019, da die Messdaten in diesem Jahr nur bis Mai erhoben wurden. Die posterioren Vorhersageverteilungen (blau schraffierte Bereiche) umfassen effektiv die gemessenen Werte und zeigen eine angemessene Quantifizierung der Unsicherheit auf der Jahresskala.

Die Vorhersagefähigkeit des Modells wird besonders in der Spitzenzeit 2016 deutlich, wo es den maximalen Verbrauch von etwa 100 kWh/m² genau erfasst. Das kalibrierte Modell reproduziert auch erfolgreich den allmählichen Rückgang der Energienachfrage von 2016 bis 2019 und beweist damit seine Fähigkeit, langfristige Trends zu erfassen und gleichzeitig Parameterunsicherheiten durch probabilistische Vorhersagen zu berücksichtigen. Diese Validierung bestätigt die Wirksamkeit des implementierten Frameworks bei der Verbesserung der Vorhersagegenauigkeit des Modells und liefert gleichzeitig quantifizierbare Unsicherheitsmaße für die Bewertung der Gebäudeenergieeffizienz.




Abbildung 37 Kalibrierte Modellergebnisse als posteriore Wahrscheinlichkeitsverteilungen im Verhältnis zu den ursprünglichen Modellergebnissen vor der Kalibrierung (rot) und den entsprechenden Messdaten für die jährliche Zeitauflösung




Abbildung 38 Kalibrierte Modellergebnisse als posteriore Wahrscheinlichkeitsverteilungen im Verhältnis zu den ursprünglichen Modellergebnissen vor der Kalibrierung (rot) und den entsprechenden Messdaten für die monatliche Zeitauflösung

Für die monatliche Auflösung (siehe Abbildung 38) erfasst das kalibrierte Modell effektiv die saisonalen Muster und zeigt einen Spitzenbedarf von 15-20 kWh/m² während der Wintermonate und minimale Werte während der Sommerperioden. Während das Modell im Vergleich zu seiner unkalibrierten Version eine verbesserte Genauigkeit bei der Wiedergabe der saisonalen Übergänge aufweist, bleibt eine systematische Einschränkung bei den Vorhersagen im Sommer bestehen. Insbesondere simuliert das im Rahmen der Studie verwendete DIBS-Gebäudeenergiemodell in den Sommermonaten durchweg einen Heizenergiebedarf von Null, da es den in den Messdaten gemessenen Warmwasserbedarf nicht berücksichtigt, während die Messdaten einen minimalen, aber nicht Null-Verbrauch zeigen (2-3 kWh/m²). Diese Diskrepanz ist eher auf die Architektur des aktuellen Modells als auf eine Kalibrierungsbeschränkung zurückzuführen. Die Integration von Gebäudeenergiemodellen mit einer differenzierteren Behandlung von Schwachlastzeiten und einer besseren Darstellung der sommerlichen Heizungsdynamik könnte die Vorhersagefähigkeiten des Frameworks verbessern, insbesondere während saisonaler Übergänge und Zeiten mit geringer Nachfrage.




Abbildung 39 Kalibrierte Modellergebnisse als posteriore Wahrscheinlichkeitsverteilungen im Verhältnis zu den ursprünglichen Modellergebnissen vor der Kalibrierung (rot) und den entsprechenden Messdaten für die monatliche Zeitaufösung

Bei wöchentlicher Auflösung (siehe Abbildung 39) zeigt das kalibrierte Modell eine robuste Leistung bei der Erfassung der kurzfristigen Dynamik der Heizungsnachfrage, wie die detaillierte Analyse der Heizperiode 2019 zeigt. Das Modell bildet sowohl den allgemeinen saisonalen Übergang vom Winter zum Frühling (Januar bis Mai) als auch die feineren wöchentlichen Variationen der Nachfragemuster erfolgreich ab. Die posterioren Vorhersageverteilungen, die durch blaue Unsicherheitsbalken dargestellt werden, verbreitern sich auf dieser zeitlichen Skala angemessen, um die erhöhte kurzfristige Variabilität widerzuspiegeln und gleichzeitig eine ausreichende Präzision für operative Erkenntnisse beizubehalten.

Die Wirksamkeit des Frameworks über mehrere zeitliche Skalen hinweg bestätigt seine Vielseitigkeit als Kalibrierungsinstrument. Jede Auflösung bietet ergänzende Einblicke in die Gebäudeleistung: Die jährliche Kalibrierung erfasst langfristige Verbrauchstrends und allgemeine Modellverzerrungen, die monatliche Auflösung zeigt saisonale Muster und die Reaktion des Systems auf Klimaschwankungen, während die wöchentliche Kalibrierung zum Verständnis der Betriebsdynamik und des kurzfristigen Systemverhaltens beitragen kann. Diese Multi-Resolution-Fähigkeit macht das Framework besonders wertvoll für verschiedene Anwendungen, von der langfristigen Energieplanung bis zur detaillierten Betriebsoptimierung.

Bewertung der Kalibrierungsqualität:

Die Leistung des kalibrierten Modells wurde anhand der Kriterien der ASHRAE-Richtlinie 14 für verschiedene zeitliche Auflösungen bewertet, wobei sich unterschiedliche Genauigkeitsgrade zeigten. Bei wöchentlicher Auflösung erreichte das Modell einen CV(RMSE) von 11,62 % und ein R^2 von 0,927, was auf eine robuste kurzfristige Vorhersagefähigkeit hinweist. Bei der monatlichen Auflösung war der CV(RMSE) mit 24,63 % und einem R^2 von 0,850 höher, was auf eine größere Unsicherheit bei mittelfristigen Vorhersagen hindeutet. Das Modell mit jährlicher Auflösung wies einen CV(RMSE) von 7,10 % und R^2 von 0,921 auf und übertraf damit die jährlichen Kalibrierungskriterien von (CV(RMSE) < 15 % für monatliche und < 5 % für jährliche Vorhersagen).

Die zunehmenden R^2 -Werte von monatlichen (0,850) zu jährlichen (0,921) Auflösungen deuten auf eine verbesserte Modellgenauigkeit auf längeren Zeitskalen hin, während die unterschiedlichen CV(RMSE)-Werte in den verschiedenen Auflösungen (11,62 %, 24,63 % bzw. 7,10 %) darauf hindeuten, dass die Vorhersagegenauigkeit des Modells von der Auflösung abhängig ist. Diese Metriken bestätigen die Wirksamkeit des Bayes'schen Kalibrierungsframeworks, insbesondere für langfristige

Energiebedarfsprognosen, während sie gleichzeitig die Herausforderungen bei der Erfassung von kurzfristigen Schwankungen der Gebäudeenergieeffizienz hervorheben.

8.2.7 Qualität der Kalibrierung

In Abbildung 40 ist die Kalibrierungsqualität des Modells für verschiedene zeitliche Auflösungen der Messdaten dargestellt, die wiederum auch als Auflösung der Modellausgabe dienen. Diese Analyse untersucht zwei Schlüsselfragen: erstens die optimale Häufigkeit der Messdatenerfassung, um eine effektive Modellkalibrierung zu gewährleisten, und zweitens die notwendige Länge der Datenerfassung für robuste Kalibrierungsergebnisse.




Abbildung 40 CV(RMSE) und R^2 Leistungsmetriken für die Modellkalibrierung: Vergleich über zeitliche Auflösungen (monatlich (M), dreimonatlich (3M), halbjährlich (6M) und jährlich (Y)) und Trainingsdatenverhältnisse (20-80%)

Um die Auswirkungen dieser Faktoren zu bewerten, wurde die Kalibrierung mit unterschiedlich langen Messdaten für jede der vier zeitlichen Auflösungen durchgeführt: jährlich, halbjährlich, vierteljährlich und monatlich. Der Zeitraum für die Messung des Wärmeenergieverbrauchs von Gebäuden ist für alle Auflösungen gleich und erstreckt sich vom 16. Januar 2014 bis zum 18. Mai 2019. Zu beachten ist, dass die wöchentlichen Daten, die im vorherigen Abschnitt vorgestellt wurden, von dieser Analyse ausgeschlossen wurden, da sie nicht denselben Zeitraum abdecken; ihre Einbeziehung würde zu einem verfälschten Vergleich führen.

Wie in Abbildung 40 dargestellt, hat die Länge der erfassten Messdaten nicht unbedingt einen Einfluss auf die Qualität der Kalibrierung. Für das betreffende Gebäude ist ein Datensatz, der für nur ein Jahr (Trainingsquote = 20 %) gesammelt wurde, vom 16. Januar 2014 bis zum 31. Dezember 2014, ausreichend für die Vorhersage des Wärmeenergieverbrauchs. Das bedeutet, dass für dieses spezifische Gebäude, das Framework mit dem integrierten DIBS anwendet wird, eine gute Kalibrierung des Wärmeenergieverbrauchs erreicht werden kann. Dies vereinfacht die Datenerfassung immens, da nur eine Summe des jährlichen Wärmeenergieverbrauchs benötigt wird, ohne dass eine höhere Auflösung der Messungen oder längere Zeiträume der Datenerfassung erforderlich sind. Allerdings hat die zeitliche Auflösung der Daten einen erheblichen Einfluss. Eine jährliche Auflösung ergibt die genaueste Modellkalibrierung, wenn sowohl die Kalibrierung als auch die Auswertung auf jährlicher Basis durchgeführt werden. Im Gegensatz dazu schneidet die höchste Auflösung am schlechtesten ab, wenn Kalibrierung und Auswertung auf Monatsbasis durchgeführt werden. Für den betrachteten

Messzeitraum erzielt das Framework mit dem integrierten DIBS-Gebäudeenergiemodell die beste Leistung mit jährlichen Daten.

Bei der Vorhersage des Energieverbrauchs mit höherer zeitlicher Auflösung gibt es mehr Datenpunkte und größere Schwankungen bei den Werten. Im Gegensatz dazu werden bei niedrigeren zeitlichen Auflösungen die Schwankungen tendenziell geglättet. Infolgedessen führt eine höhere zeitliche Auflösung zu mehr Fehlermöglichkeiten im Modell. Aus diesem Grund werden in der ASHRAE-Richtlinie 14 strengere Anforderungen an die Kalibrierungsqualität von Modellen mit geringerer zeitlicher Auflösung (z. B. jährlich) gestellt (ASHRAE, 2014). Die in Abschnitt 8.2.6 vorgestellten Ergebnisse, bei denen die Kalibrierung mit wöchentlicher Auflösung bessere Leistungskennzahlen aufweist, stellen diese Vorstellung jedoch in Frage. Eine genauere Betrachtung der DIBS-Ausgabe und der gemessenen Daten, wie in Abbildung 19 für die wöchentliche Auflösung und Abbildung 20 für die monatliche Auflösung dargestellt, zeigt, dass bereits das nicht kalibrierte Modell den Schwankungen der gemessenen Daten für die wöchentliche Auflösung besser folgt als für die monatliche Auflösung.

Diese Diskrepanz kann auf die Eigenschaften des DIBS-Modells zurückgeführt werden, das in den Sommermonaten in der Regel einen Wärmeenergiebedarf nahe Null simuliert. Infolgedessen kann das Modell selbst nach der Kalibrierung nicht vollständig mit den gemessenen Daten für die Sommermonate übereinstimmen, da das Modell den in den gemessenen Wärmeenergiekosten enthaltenen Warmwasserbedarf nicht berücksichtigt. Während der Kalibrierung wird deutlich, dass das DIBS-Modell Schwierigkeiten hat, mit den beobachteten Werten für die Sommermonate übereinzustimmen, da es nicht zwischen Raumheizung und Warmwasserverbrauch unterscheidet. Dieses Problem könnte entweder durch den Ausschluss von Warmwasserdaten aus den für die Kalibrierung verwendeten Messdaten oder durch die Einbeziehung des Warmwasserverbrauchs in das DIBS-Modell behoben werden.

Diese Ergebnisse unterstreichen die Empfindlichkeit von Gebäudeenergiemodellen, der Qualität der Eingabedaten und des Kalibrierungsprozesses für Vorhersagen. Obwohl das Framework vollständig automatisiert ist, um die optimalen Kalibrierungsergebnisse zu finden, hängt die Genauigkeit des Tools immer noch stark von der Qualität der Daten und des verwendeten Modells ab. Dies unterstreicht die Notwendigkeit strengerer Standards für die Datenerfassung und die Kalibrierung von Gebäudeenergiemodellen, um robuste und zuverlässige Ergebnisse zu gewährleisten.

8.3 Überblick

In diesem Rahmen sind die Rechenzeit und die Qualität der Kalibrierung zwei kritische Faktoren. Abbildung 41 zeigt die gesamte Rechenzeit, die für die Ausführung des gesamten Frameworks erforderlich ist, während Abbildung 42 die erreichten Qualitätswerte anzeigt und sie mit den ASHRAE-Normen vergleicht, die für jede spezifische Fallstudie erforderlich ist.

Die Ergebnisse zeigen, dass die jährliche Kalibrierung für Fallstudie 1 unter Verwendung von Klimadaten des Testreferenzjahres und die wöchentliche Kalibrierung für Fallstudie 2 unter Verwendung von Daten des tatsächlichen meteorologischen Jahres die am wenigsten rechenintensiven Optionen sind. Bemerkenswert ist, dass die Qualität der Kalibrierung für Fallstudie 1 (TRY) deutlich höher ist. Diese Diskrepanz ist wahrscheinlich auf das längere Zeitintervall der für Fallstudie 1 verwendeten Messdaten zurückzuführen, das sich über sechs Jahre erstreckt, während Fallstudie 2 (wöchentlich) auf nur 14 Wochen Trainingsdaten zurückgreift. Dies führt zu ähnlichen Rechenzeiten, aber zu einer deutlich besseren Kalibrierungsqualität für Fallstudie 1.




Abbildung 41 Berechnungszeiten für die Fallstudien

In Abbildung 41 stellen die dunkleren Farben die in den ASHRAE-Normen festgelegten Qualitätsschwellenwerte dar, während die helleren Farben die in der Studie erreichten Qualitätswerte zeigen. Gemäß den ASHRAE-Anforderungen müssen die CV(RMSE)-Werte unter den jeweiligen Qualitätsschwellenwerten bleiben, und die R^2 -Werte müssen die festgelegten Grenzwerte überschreiten. Die R^2 -Kriterien werden durchweg erfüllt, was zeigt, dass das kalibrierte Modell die gemessenen Daten genau wiedergibt. Ebenso erfüllen die CV(RMSE)-Werte in den meisten Szenarien die geforderten Standards, was darauf hinweist, dass die Unterschiede zwischen den gemessenen Daten und dem kalibrierten Modell gering sind. Allerdings wird das CV(RMSE)-Kriterium für die monatliche und die jährliche Kalibrierung in Fallstudie 2 nicht erfüllt.

Der Rahmen zeigt ein erhebliches Potenzial für eine effiziente Kalibrierung, sowohl hinsichtlich des Zeitbedarfs als auch der erreichten Kalibrierungsqualität, bei der lediglich jährliche Messdaten verwendet werden. Dies ist besonders effektiv, wenn Klimadaten aus dem Testreferenzjahr einbezogen werden. Durch die Minimierung der Abhängigkeit von spezifischen Klimadatensätzen rationalisiert dieser Ansatz den Kalibrierungsprozess und erleichtert die direkte Anwendung von vorab gespeicherten Klimaanpassungsfaktoren, die in das System integriert sind. Diese Erweiterungen verbessern sowohl die Effizienz als auch die Zugänglichkeit des Kalibrierungsprozesses.




Abbildung 42 Bewertungen der Kalibrierungsqualität im Vergleich zu den Anforderungen von Ashrae

8.3 Open-Source-Repository

Das Open-Source-Repository ist unter folgendem Link zu finden:

<https://github.com/TUB-DVG/CalibLab>

Das wichtigste Ergebnis dieses Forschungsprojekts ist ein Open-Source-Repository, das in diesem Abschnitt ausführlich beschrieben wird. Dieses Repository dient als grundlegende Ressource und bietet wesentliche Funktionen und Spezifikationen zur Unterstützung der Kalibrierung von Gebäudeenergiemodellen. In diesem Abschnitt geben wir einen Überblick über die Anforderungen an das Repository, eine Beschreibung seiner Kernfunktionen und eine praktische Anleitung zur effektiven Nutzung, einschließlich Anweisungen zur Installation, zum Betrieb und zur Integration mit ergänzenden Tools. Das Repository ist so konzipiert, dass es sowohl für Forscher als auch für Fachleute aus dem gesamten Gebäudesektor zugänglich und benutzbar ist und sich an Benutzer mit unterschiedlichem Erfahrungsstand richtet.

Wir ermutigen andere Forscher nachdrücklich, dieses Repository weiterzuentwickeln, indem sie Funktionalitäten hinzufügen oder Verbesserungen vorschlagen. Solche gemeinsamen Bemühungen werden dazu beitragen, ein konsensorientiertes, weithin akzeptiertes Werkzeug zu schaffen, das die Genauigkeit und Zuverlässigkeit von Kalibrierungen von Gebäudeenergiemodellen verbessert. Dieser kollektive Entwicklungsansatz wird dazu beitragen, eine vielseitige und robuste Ressource für die Forschungsgemeinschaft und die Industrie gleichermaßen zu schaffen.

8.3.1 Datenanforderungen

Das Framework erfordert vom Benutzer bereitgestellte Daten, insbesondere Messdaten, die in einer Excel-Datei formatiert sind und die entsprechenden Messdaten enthalten. Zusätzlich ist eine Excel-Datei mit den anfänglich angenommenen Parameterwerten erforderlich, zusammen mit einer separaten Datei, die den Grad der Unsicherheit für jeden Parameter definiert. Der Unsicherheitsgrad jedes Parameters sollte als "informativ", "schwach informativ" oder "nicht informativ" kategorisiert werden.

Das aktuelle Repository enthält einen umfassenden Klimadatensatz für Berlin, der reale Wetterdaten aus den Jahren 2010 bis 2022 enthält. Dieser Datensatz repräsentiert reale meteorologische Jahre und bietet den Nutzern detaillierte, historisch genaue Klimainformationen speziell für Berlin. Diese Daten ermöglichen eine präzise Kalibrierung und Prüfung von Energiemodellen in diesem spezifischen geografischen und klimatischen Kontext. Für die Kalibrierung mit tatsächlichen meteorologischen Jahresklimadaten für einen anderen Ort als Berlin müssen die Nutzer den entsprechenden Klimadatensatz in das Tool hochladen.

Das Repository enthält eine Testreferenzjahr-Klimadatei für Potsdam. TRY-Dateien sind standardisierte Datensätze, die typische meteorologische Bedingungen an einem bestimmten Ort darstellen und einen zuverlässigen Maßstab für die Prüfung und Validierung von Modellen bieten. Diese Einbeziehung ermöglicht es den Nutzern, Simulationen unter standardisierten Bedingungen durchzuführen und so eine vergleichende Basislinie zu schaffen, die für die Kalibrierung von Modellen in verschiedenen Regionen oder Szenarien nützlich ist.

Um den Nutzen des Datensatzes weiter zu erhöhen, werden Klimaanpassungsfaktoren für eine Vielzahl von Regionen in Deutschland bereitgestellt. Konkret enthält der Datensatz diese Anpassungsfaktoren für 8234 Postleitzahlgebiete im ganzen Land. Diese Anpassungsfaktoren ermöglichen es den Nutzern, ihre Energiemodelle lokal anzupassen, indem sie sie mit spezifischen regionalen Klimavariationen in Einklang bringen, ohne dass sie Klimadaten für jedes einzelne Gebiet suchen und herunterladen müssen. Diese Funktion vereinfacht die Nutzung des Rahmenwerks, da bei der Simulation von Standorten außerhalb Berlins keine zusätzlichen Klimadaten benötigt werden.

Darüber hinaus verbessert dieser Ansatz die Effizienz des Frameworks erheblich, da die Simulation während des iterativen Kalibrierungsprozesses nur für ein einziges repräsentatives Jahr ausgeführt werden muss und nicht für jedes Jahr innerhalb eines historischen Datensatzes. Durch die Anwendung der Klimaanpassungsfaktoren auf ein einziges Testreferenzjahr können die Benutzer die Simulationsergebnisse so erweitern, dass sie jährliche Schwankungen darstellen und einen Zeitreihendatensatz für die Region ohne zusätzliche Durchläufe erstellen. Diese Fähigkeit vereinfacht den Arbeitsablauf und beschleunigt den Modellierungsprozess, so dass die Benutzer in einem Bruchteil der Zeit, die für herkömmliche Methoden benötigt wird, genaue, standortspezifische Ergebnisse erzeugen können.

Alle im Repository enthaltenen Klimadaten und Anpassungsfaktoren stammen vom Deutschen Wetterdienst (DWD) und sind für die öffentliche Nutzung frei zugänglich. Durch die Integration dieser geprüften, öffentlich zugänglichen Datensätze bietet das Repository eine robuste und zuverlässige Grundlage für Nutzer, die an Energiemodellierungsprojekten in unterschiedlichen klimatischen Kontexten in Deutschland arbeiten. Diese umfangreiche Klimadatenbibliothek stellt sicher, dass Forscher und Fachleute Zugang zu qualitativ hochwertigen, geographisch relevanten Daten haben, was die Präzision und Anpassungsfähigkeit ihrer Energiemodelle verbessert.

8.3.2 Benutzereingaben

Die Benutzer müssen für den Kalibrierungsprozess bestimmte Entscheidungen treffen. Zunächst müssen sie den Prozentsatz der Messdaten festlegen, der für die Kalibrierung und nicht für die Prüfung verwendet wird. Dies bedeutet, dass festgelegt werden muss, welcher Anteil der Messdaten für die Kalibrierung verwendet wird und welcher Anteil für die Vorhersage und Bewertung der Kalibrierungsqualität reserviert wird. Darüber hinaus müssen die Nutzer die Anzahl der Kalibrierungsparameter festlegen, indem sie angeben, für wie viele der gesamten Parameter im Gebäudeenergiemodell neue Kalibrierungswerte verwendet werden sollen. In der Literatur wird empfohlen, maximal fünf Parameter zu verwenden, um optimale Ergebnisse zu erzielen.

In der Hauptskriptdatei muss der Benutzer eine Gebäude-ID angeben, angeben, ob die Kalibrierung TRY- oder AMY-Klimadaten verwendet, und die Ausgabeauflösung festlegen (z. B. jährlich, monatlich, wöchentlich). Für die TRY-basierte Kalibrierung sollte die Ausgabeauflösung auf "Keine" gesetzt werden. Außerdem muss der Name der Klimadatei angegeben werden; wenn die TRY-Methode gewählt wird, sollte dieses Feld ebenfalls auf "Keine" gesetzt werden.

Die Benutzer können auch Entscheidungen über die iterative Ausführung bestimmter Rahmenkomponenten treffen, bis eine Datenkonvergenz erreicht ist. Diese Option ist insbesondere für die Empfindlichkeitsanalyse und die Erstellung von Metamodellen relevant. Bei der Sensitivitätsanalyse beinhaltet die Konvergenz die Erhöhung des Stichprobenumfangs für die Berechnung des Sensitivitätsindex, bis sich die Rangfolge der Parameter stabilisiert und die Identifizierung der empfindlichsten Parameter gewährleistet ist. Für das Metamodell beinhaltet die Konvergenz die Erhöhung des Stichprobenumfangs, bis das Modell die Qualitätskriterien erfüllt und das ursprüngliche Modell genau repräsentiert. Dieser Schritt umfasst auch das Testen verschiedener Gaußscher Regressionskerne zur Optimierung des Metamodells. Wenn keine Konvergenz ausgewählt wird, werden Standardwerte verwendet, die sich in früheren Studien als zuverlässig erwiesen haben. Diese Standardwerte gewährleisten jedoch nicht immer optimale Ergebnisse oder Anpassungen für neue Datentypen.

8.3.3 Back-End-Prozesse

Die Hauptskriptdatei umreißt die aufeinanderfolgenden Schritte innerhalb des Frameworks. Jeder Schritt fungiert als Berechnungsblock, der die notwendigen zugrunde liegenden Funktionen zur Ausführung seiner spezifischen Aufgabe aufruft.

1. In einem ersten Schritt wird die Simulation mit den vordefinierten Parameterwerten durchgeführt, die das Gebäudeenergiemodell vor der Kalibrierung darstellen. In dieser Phase läuft das Modell mit diesen vorläufigen Parameterwerten und ermöglicht einen Vergleich zwischen der Modellausgabe und den tatsächlich gemessenen Daten für den untersuchten Fall. Diese anfängliche Ausgabe kann in einem Diagramm visualisiert werden, um die Modellleistung im Vergleich zu den beobachteten Daten zu bewerten.
2. Im zweiten Schritt wird eine Sensitivitätsanalyse durchgeführt, um die Parameter zu ermitteln, die den größten Einfluss auf die Modellsimulation haben. Die vorherige Wahl bezüglich der Konvergenz der Sensitivitätsanalyse bestimmt, welche zugrunde liegende Funktion in diesem Schritt aufgerufen wird. Außerdem wirkt sich die gewählte Anzahl der Kalibrierungsparameter auf den Konvergenzprozess aus; die Analyse wird so lange wiederholt, bis dieselben Parameter unter der angegebenen Anzahl von Kalibrierungsparametern durchgängig als die empfindlichsten eingestuft werden. Die Ausgabe dieses Schritts enthält die Namen der empfindlichsten Parameter.
3. Das nächste Modul konzentriert sich auf die Erstellung des Metamodells, das aus zwei Prozessen besteht. Im ersten Prozess werden die empfindlichsten Parameter, die im vorangegangenen Schritt ermittelt wurden abgetastet und die Simulation des Gebäudeenergiemodells wird für jede Kombination von Abtastungen durchgeführt, wobei die Ergebnisse für die weitere Analyse gespeichert werden.

Im zweiten Prozess werden diese Stichprobendaten verwendet, um das Metamodell mithilfe der Gaußschen Regression zu trainieren. Die Wahl des Stichprobenumfangs für das Training und die Auswertung kann sich erheblich auf die Genauigkeit des Metamodells auswirken. Der Standardwert ist auf 75 % festgelegt, kann aber bei Bedarf innerhalb des Moduls angepasst werden. Wie bereits erwähnt, kann der Benutzer auch entscheiden, ob Konvergenz erforderlich

ist, bevor er das Modul aufruft. Wenn keine Konvergenz ausgewählt wird, wird die vordefinierte Anzahl von Parameterkombinationsstichproben für das Modelltraining ausgeführt, wobei der Standard-Kernel-Typ für die Gauß-Prozesse verwendet wird.

Wenn Konvergenz gewählt wird, wird die Anzahl der Stichproben erhöht, bis die Kriterien für ein ausreichend genaues Metamodell erfüllt sind und es werden mehrere Kernel getestet, um sicherzustellen, dass das Metamodell die spezifischen Daten und das Gebäudeenergiemodell genau wiedergibt. Die Ausgabe dieses Moduls ist das Metamodell selbst, das in einem Format gespeichert wird und dann im nachfolgenden Modul verwendet werden kann.

4. Der letzte Block des Frameworks konzentriert sich auf die Bayes'sche Kalibrierung des Gebäudeenergiemodells, wobei die gemessenen Daten zur Verbesserung der Modellgenauigkeit verwendet werden. Dieses Modul nutzt den zu Beginn des Frameworks definierten Umfang der Messdaten, während der Rest für Auswertungszwecke beiseite gelegt wird.

Der Prozess beginnt mit der Erstellung von prioritären Wahrscheinlichkeitsverteilungen für die Parameter, wobei die zuvor definierten Parameterwerte und Unsicherheitsgrade als Benutzereingaben verwendet werden. Um diese Schätzungen zu verfeinern, wendet das Modul eine Monte-Carlo-Markov-Ketten-Methode in einem zugrunde liegenden Prozess an. Der Monte-Carlo-Aspekt bezieht sich auf die Zufallsstichproben aus den prior Parameterverteilungen, während die Markov-Ketten-Komponente bedeutet, dass jede Stichprobe von der vorherigen abhängt, wodurch eine Kette von Stichproben entsteht, die gegen die Zielverteilung konvergieren. Während des MCMC-Prozesses werden Stichproben aus den Wahrscheinlichkeitsverteilungen der Prior-Parameter gezogen. Für jeden abgetasteten Parametersatz wird die Likelihood berechnet, die angibt, wie gut die Ergebnisse der Modellsimulation mit den beobachteten Messdaten übereinstimmen. Auf der Grundlage dieser Likelihood-Berechnungen erzeugt der Prozess einen neuen Satz von Parameterwahrscheinlichkeitsverteilungen. Dieses iterative Sampling wird fortgesetzt, bis die festgelegte Anzahl akzeptierter Stichproben erreicht ist.

Um die Konvergenz festzustellen, werden die gesammelten Stichproben anhand vordefinierter Kriterien bewertet. Wenn die Stichproben diese Kriterien erfüllen, gilt die Konvergenz als erreicht, was bedeutet, dass sich die Parameterschätzungen stabilisiert haben. Ist dies nicht der Fall, wird eine neue Zielstichprobengröße festgelegt, und der MCMC-Prozess beginnt von neuem.

Das Ergebnis dieses Moduls ist die posteriore Wahrscheinlichkeitsverteilung für die Kalibrierungsparameter, die eine verfeinerte Schätzung der Parameterwerte liefert, die die beobachteten Daten am besten erklären. Diese posteriore Verteilung dient als wichtiges Ergebnis, das Informationen für nachfolgende Modellierungsbemühungen liefert und die Gesamtgenauigkeit des Gebäudeenergiemodells verbessert.

5. Nach Erhalt der posterioren Wahrscheinlichkeitsverteilungen für die Modellparameter werden diese Verteilungen innerhalb des Gebäudeenergiemodells angewendet, um kalibrierte Simulationsergebnisse zu erzeugen. Dieser Simulationsprozess nutzt die neu kalibrierten Parameterwerte, was zu einer Posterior-Wahrscheinlichkeitsverteilung für die vorhergesagten Energieoutputs des Modells führt. Diese Ergebnisse stellen die verfeinerten Vorhersagen des Modells dar, wobei die während der Kalibrierung ermittelten Unsicherheiten berücksichtigt werden. Die sich daraus ergebende Verteilung wird als das vollständig kalibrierte Modell betrachtet, das die Parameterwerte widerspiegelt, die am besten zu den beobachteten Daten passen und ein zuverlässigeres Simulationsergebnis bieten.

6. Um die Leistung des kalibrierten Modells gründlich zu bewerten, muss seine Ausgabe anhand des verbleibenden Segments der Messdaten validiert werden, das zuvor für die Bewertung zurückgestellt wurde. Dazu werden wichtige Leistungsindikatoren wie der Variationskoeffizient des mittleren quadratischen Fehlers (Root Mean Square Error) und das Bestimmtheitsmaß über die gesamte Wahrscheinlichkeitsverteilung der simulierten Ergebnisse des kalibrierten Modells berechnet. Diese Werte werden dann in einer separaten Ergebnisdatei gespeichert, in der die Leistungskennzahlen sowohl für die Wahrscheinlichkeitsverteilung als auch für die optimalen Einzelparameterkombinationen (die den niedrigsten CV(RMSE) und das höchste R^2 ergeben) dokumentiert werden. Für eine gründliche Bewertung sollten diese Werte mit den in der ASHRAE-Richtlinie 14 festgelegten Benchmarks verglichen werden, die in Kapitel 7 unter "Ziel 7" näher erläutert werden, um sicherzustellen, dass die Genauigkeit und die Vorhersagefähigkeiten des Modells mit den etablierten Standards übereinstimmen.

7. Mehrere Skripte wurden in das Framework aufgenommen, um die Visualisierung der verschiedenen Phasen und Ergebnisse zu erleichtern. Diese Skripte sind so konzipiert, dass sie eine Vielzahl von Diagrammen erzeugen, darunter:
 - Simulationsergebnisse des Gebäudeenergiemodells: Diese Darstellung vergleicht die Simulationsergebnisse des Gebäudeenergiemodells mit den entsprechenden Messdaten über denselben Zeitraum.
 - Konvergenz der Empfindlichkeitsanalyse: Diese Grafik veranschaulicht, wie sich die Rangfolge der Modellparameter mit zunehmendem Stichprobenumfang ändert, und gibt Aufschluss darüber, wie sich die Konvergenz für die Empfindlichkeit der verschiedenen Parameter entwickelt.
 - Konvergenz des Gaußschen Regressionsprozesses: Dieses Diagramm zeigt die Bewertungsmetriken und die erforderliche Rechenzeit für verschiedene Stichprobengrößen an und ermöglicht so eine Bewertung der Effizienz und Effektivität der Gaußschen Regression im Konvergenzprozess.
 - Metamodell-Vergleich: In dieser Darstellung wird das Meta-Modell dem ursprünglichen Gebäudeenergiemodell gegenübergestellt, um zu bewerten, wie genau das Meta-Modell das Verhalten des ursprünglichen Modells wiedergibt.
 - Kalibrierungsprozess-Spuren: Diese Visualisierung verfolgt die akzeptierten Parameterwerte während des gesamten Kalibrierungsprozesses und bietet einen detaillierten Überblick darüber, wie sich die Parameter über Iterationen hinweg entwickeln.
 - Prior- und Posterior-Parameterwahrscheinlichkeitsverteilungen: Dieses Diagramm zeigt die Veränderungen in den Parameterwahrscheinlichkeitsverteilungen und hebt hervor, wie sich die Posterior-Verteilungen nach der Kalibrierung von den Prior-Verteilungen unterscheiden.
 - Kalibriertes Gebäudeenergiemodell - Simulationsergebnisse: Diese Reihe von Diagrammen zeigt die Simulationsergebnisse des kalibrierten Gebäudeenergiemodells über die gesamte Zeitreihe, wobei die für die Kalibrierung und Vorhersage verwendeten Zeitreihen deutlich markiert sind. Sie enthält auch die Simulationsergebnisse vor der Kalibrierung und die entsprechenden Messdaten.
 - Voraussagende Szenarien: Diese Diagramme stellen verschiedene Nachrüstungssimulationen dar, die die potenziellen Energieeinsparungen und Treibhausgasemissionen (THG) sowie die damit verbundenen Unsicherheiten veranschaulichen. Sie geben Aufschluss über das Maß an Vertrauen in die Erzielung bestimmter Energieeinsparungen und Treibhausgasreduzierungen durch bestimmte Nachrüstungsmaßnahmen.

Abbildung 43 veranschaulicht den Aufbau und die Funktionsweise des Git-Repository und zeigt die verschiedenen in diesem Bericht beschriebenen Schritte auf. Sie zeigt auch die erforderlichen und optionalen Benutzereingaben auf, die für den Betrieb erforderlich sind.




Abbildung 43 Schematische Darstellung der Struktur des Git-repository

9 Schlussfolgerung und Ausblick

Das in dieser Studie entwickelte Framework demonstriert die Effektivität der Anwendung von Bayes'schen Statistiken bei der Kalibrierung von Energiemodellen für Gebäude, indem es sowohl eine verbesserte Anpassung an beobachtete Daten als auch eine rigorose Behandlung inhärenter Unsicherheiten ermöglicht. Durch den Einsatz von Bayes'schen Techniken kalibriert das Framework effizient Modelle und erzeugt robuste Vorhersagen, die eher probabilistische Bereiche als deterministische Ergebnisse beinhalten. Dieser Ansatz erhöht nicht nur die Zuverlässigkeit der Vorhersagen, sondern bietet auch ein detailliertes Verständnis der mit jedem Parameter verbundenen Unsicherheiten, wodurch das Vertrauen in die Modellergebnisse gestärkt wird, was deren Verwendung bei weiteren Analysen und Entscheidungen unterstützt. Darüber hinaus wird die Glaubwürdigkeit des Frameworks durch die erfolgreiche Prüfung an realen Gebäudedaten und nicht nur an Daten aus kontrollierten Umgebungen gestärkt.

Das Framework ist auf Benutzerfreundlichkeit ausgelegt, erfordert nur minimale Eingabedaten, wählt automatisch bestimmte Werte für Schlüsselparameter aus und reduziert den Bedarf an Benutzerinteraktion. Dieser rationalisierte Ansatz ermöglicht es Benutzern, auch wenn sie nur begrenzten Zugang zu detaillierten Gebäudedaten haben, effizient kalibrierte Modelle zu erstellen. Ein wesentliches Merkmal zur Verbesserung der Zugänglichkeit ist die automatische Integration aller Schritte des Frameworks. Nach dem Start arbeitet das Framework autonom und nutzt einen selbstanpassenden Algorithmus für die Konvergenzsuche, um die optimalen Stichprobengrößen und Hyperparameterwerte für zuverlässige Ergebnisse zu bestimmen und gleichzeitig die Berechnungseffizienz zu gewährleisten. Durch die automatische Auswahl dieser Werte auf der Grundlage der spezifischen Daten geht das System eine große Herausforderung bei der Bayes'schen Kalibrierung an - die Bestimmung von Parametern, die in der Regel eine manuelle Eingabe erfordern und ansonsten nur schwer genau festgelegt werden können. Dank dieser Anpassungsfähigkeit lässt sich das System effektiv über verschiedene Datensätze und Modelle hinweg verallgemeinern, so dass es für Benutzer mit unterschiedlichem Wissensstand zugänglich ist. In Kombination mit Multiprocessing, den schnellen Simulationsfähigkeiten von DIBS und der Metamodellierung wird die Effizienz der Berechnungen erheblich gesteigert.

Darüber hinaus enthält das Framework vorinstallierte Datensätze, wie z. B. Klimadaten des tatsächlichen meteorologischen Jahres, und ermöglicht den Zugriff auf Klimadaten des Testreferenzjahres für 8234 Orte in Deutschland. Dies minimiert die Anforderungen an die Dateneingabe und die Einrichtungszeit, da die Nutzer diese Daten nicht selbst beschaffen müssen.

Die Eingabeanforderungen des Frameworks werden auch durch die Nutzung von Funktionen des DIBS-Systems reduziert, das so angepasst wurde, dass es nahtlos in diesem Framework funktioniert. Infolgedessen werden nur 21 grundlegende Eingabeparameter benötigt, was das System für Nutzer, die eine schnelle und zuverlässige Kalibrierung von Gebäudeenergiemodellen wünschen, sehr zugänglich und effizient macht.

Das Framework ist äußerst anpassungsfähig und verfügt über austauschbare Komponenten, die es den Benutzern ermöglichen, es an ihre spezifischen Bedürfnisse anzupassen. Diese Flexibilität ermöglicht es den Nutzern, das Framework auf verschiedene Gebäudeenergiemodelle zuzuschneiden oder alternative Sensitivitätsanalysen und Metamodellierungstechniken nach Belieben anzuwenden.

Ein weiteres zentrales Merkmal ist die Recheneffizienz: Durch die Nutzung der schnellen Simulationsfähigkeiten von DIBS, die Implementierung der Gaußschen Prozessregression für die

Metamodellierung und die Aktivierung von Multiprocessing arbeitet das Framework mit hoher Geschwindigkeit und reduzierter Rechenlast.

Schließlich wurde das Framework in Python, einer weit verbreiteten Programmiersprache, entwickelt, was seine Zugänglichkeit und Kompatibilität mit verschiedenen Plattformen und Systemen verbessert. Diese Entscheidung erweitert den Nutzerkreis des Frameworks und macht es zu einem wertvollen Werkzeug für Praktiker und Forscher im Bereich der Energiemodellierung von Gebäuden.

Das Forschungsprojekt hat ein vielversprechendes Framework für die Kalibrierung von Energiemodellen für Gebäude mit Bayes'schen Methoden aufgezeigt. Das Potenzial dieses Ansatzes ist weitreichend und mehrere Schlüsselbereiche zukünftiger Arbeit könnten seine Anwendbarkeit, Genauigkeit und Relevanz für ein breiteres Spektrum von Szenarien und Skalen verbessern.

Um unsere Klimaziele effektiver zu erreichen, ist es wichtig, über einzelne Gebäude hinauszugehen und den Energieverbrauch in einem größeren, städtischen Maßstab zu betrachten. Die Anwendung dieses Frameworks auf höheren Aggregationsebenen könnte wertvolle Erkenntnisse für das Energiemanagement in Stadtvierteln und Städten liefern. Um den Rahmen auf die städtische Ebene auszudehnen, sollten künftige Arbeiten ihn jedoch anpassen und mit Modellen testen, die speziell für die städtische Energieanalyse entwickelt wurden. Da dieses Framework als Kalibrierungsinstrument und nicht als eigenständiges Modell fungiert, ist er auf ein zugrunde liegendes Modell angewiesen, das die städtische Energiedynamik erfasst. Die Kalibrierung von Modellen auf städtischer Ebene mit diesem Ansatz könnte den Städten helfen, ein tieferes Verständnis der Energieverbrauchsmuster in größeren Gebieten zu erlangen, was eine strategische Planung und ein besseres Ressourcenmanagement ermöglicht. Die Entwicklung kompatibler Energiemodelle im städtischen Maßstab und die Anwendung dieses Frameworks auf diese Modelle könnte seine Wirkung erheblich steigern und umfassendere, stadtweite Energiebewertungen unterstützen.

Während des Forschungszeitraums war der Zugang zu gemessenen Energiedaten vor und nach den Sanierungsmaßnahmen nicht möglich, was die Anwendung des Frameworks bei der Bewertung von Sanierungseinsparungen einschränkte. Infolgedessen bleiben die Vorhersagen über die Auswirkungen von Sanierungen oder Nachrüstungen eher ein Vorhersageszenario, als dass sie anhand empirischer Daten validiert werden konnten. Die Beschaffung solcher Daten und ihre Integration in künftige Studien würde eine direkte Bewertung der Genauigkeit des Frameworks bei der Vorhersage von Energieeinsparungen ermöglichen, was ein wesentlicher Schritt zur Verfeinerung der Kalibrierungsmethoden wäre.

Die Robustheit des Frameworks könnte durch die Fähigkeit zur Kalibrierung anhand mehrerer Arten von Ausgabedaten weiter verbessert werden. Durch die Kalibrierung auf mehreren Ebenen, z. B. durch Einbeziehung von Outputs für den Kühlbedarf oder den Stromverbrauch bei gleichzeitiger Verwendung desselben Satzes von Eingabeparametern, könnte das Modell ein breiteres Spektrum von Dynamiken erfassen und sowohl die Genauigkeit als auch die Relevanz erhöhen. Da die DIBS diese verschiedenen Outputs generieren kann, könnte das Framework ohne weiteres für eine mehrstufige Kalibrierung angepasst werden. Leider enthielten die Datenbanken, die für diese Forschung zur Verfügung standen, diese Informationen nicht, aber die Einbeziehung dieser Informationen könnte für zukünftige Arbeiten sehr wertvoll sein.

Gegenwärtig werden die internen Lasten, wie z.B. die Belegung, die Nutzung von Geräten und Zeitplänen im DIBS-Modell aus deutschen Normen abgeleitet. Eine Umgestaltung des Modells um diese als unbekannte kontinuierliche Parameter zu behandeln, würde die Kalibrierungsgenauigkeit erhöhen indem Unsicherheiten im Zusammenhang mit der Gebäudenutzung berücksichtigt werden. Interne Lasten sind oft sehr variabel und stellen eine bedeutende Quelle der Unsicherheit bei der

Energiemodellierung dar. Eine Kalibrierung des Modells auf der Grundlage tatsächlicher interner Lastdaten anstelle von standardisierten Annahmen könnte genauere und kontextspezifische Modellergebnisse liefern und damit einen wertvollen Bereich für die weitere Entwicklung darstellen.

Seit Beginn dieses Projekts haben die Fortschritte in der Informatik - insbesondere im Bereich des maschinellen Lernens (ML) - neue Möglichkeiten für die Energiemodellierung von Gebäuden eröffnet. Zukünftige Forschungsarbeiten könnten den aktuellen Bayes'schen Rahmen mit ML-basierten Modellen vergleichen oder hybride Ansätze untersuchen, die Bayes'sche und ML-Techniken integrieren. Solche Vergleiche könnten Synergien zwischen den Stärken der Bayes'schen Kalibrierung bei der Quantifizierung von Unsicherheiten und der Vorhersagekraft von ML aufzeigen. Durch die Untersuchung potenzieller Integrationspunkte könnten Forscher ein flexibleres und leistungsfähigeres Kalibrierungswerkzeug schaffen, dass die besten Aspekte beider Ansätze nutzt.

Die Berücksichtigung dieser Aspekte in zukünftigen Arbeiten könnte die Vielseitigkeit des Frameworks erheblich verbessern und eine breitere Akzeptanz als Reaktion auf die sich entwickelnden Anforderungen der Industrie unterstützen. Der Open-Source-Charakter des Frameworks, zusammen mit der detaillierten Dokumentation auf GitHub und unterstützenden Konferenzbeiträgen, die seine Verwendung und Fallstudien aus der Praxis beschreiben, bietet eine Grundlage für die weitere Entwicklung. Wir hoffen, dass andere Forscher und Entwickler auf dieser Arbeit aufbauen und die Fähigkeiten des Frameworks verfeinern und erweitern werden, um den Bereich der Energiemodellierung von Gebäuden voranzutreiben und nachhaltigere Energiemanagementpraktiken auf verschiedenen Ebenen zu unterstützen.

Referenzen

- Al-Shargabi, A.A., Almhafdy, A., Ibrahim, D.M., Alghieth, M., Chiclana, F., 2022. Buildings' energy consumption prediction models based on buildings' characteristics: Research trends, taxonomy, and performance measures. *Journal of Building Engineering* 54, 104577. <https://doi.org/10.1016/j.jobe.2022.104577>
- Andrade-Cabrera, C., Turner, W.J.N., Finn, D.P., 2019. Augmented Ensemble Calibration of lumped-parameter building models. *Build. Simul.* 12, 207–230. <https://doi.org/10.1007/s12273-018-0473-5>
- Bamdad, K., Cholette, M.E., Bell, J., 2020. Building energy optimization using surrogate model and active sampling. *Journal of Building Performance Simulation* 13, 760–776. <https://doi.org/10.1080/19401493.2020.1821094>
- Bhandari, M., Shrestha, S., New, J., 2012. Evaluation of weather datasets for building energy simulation. *Energy and Buildings* 49, 109–118. <https://doi.org/10.1016/j.enbuild.2012.01.033>
- Bischof, J., Knoll, S., Duffy, A., 2022. Development Of A Python-Based Simplified Hourly Building Model For Non-Domestic Building Stock Operational Energy Simulations. Presented at the BauSim Conference 2022. <https://doi.org/10.26868/29761662.2022.5>
- Borgonovo, E., 2007. A new uncertainty importance measure. *Reliability Engineering & System Safety* 92, 771–784. <https://doi.org/10.1016/j.ress.2006.04.015>
- Bornatico, R., Hüsey, J., Witzig, A., Guzzella, L., 2013. Surrogate modeling for the fast optimization of energy systems. *Energy* 57, 653–662. <https://doi.org/10.1016/j.energy.2013.05.044>
- Bourgeois, D., Reinhart, C., Macdonald, I., 2006. Adding advanced behavioural models in whole building energy simulation: A study on the total energy impact of manual and automated lighting control. *Energy and Buildings* 38, 814–823. <https://doi.org/10.1016/j.enbuild.2006.03.002>
- Burhenne, S., Jacob, D., Henze, G.P., 2011. Sampling based on Sobol' sequences for Monte Carlo techniques applied to building simulations, in: *Proceedings of Building Simulation*. Presented at the 12th Conference of International Building Performance Simulation Association, Sydney. <https://publica.fraunhofer.de/handle/publica/375074>
- Campolongo, F., Cariboni, J., Saltelli, A., 2007. An effective screening design for sensitivity analysis of large models. *Environmental Modelling & Software* 22, 1509–1518. <https://doi.org/10.1016/j.envsoft.2006.10.004>
- Cant, K., Evins, R., 2023. Improved calibration of building models using approximate Bayesian calibration and neural networks. *Journal of Building Performance Simulation* 16, 291–307. <https://doi.org/10.1080/19401493.2022.2137236>
- Chong, A., Gu, Y., Jia, H., 2021. Calibrating building energy simulation models: A review of the basics to guide future work. *Energy and Buildings* 253, 111533. <https://doi.org/10.1016/j.enbuild.2021.111533>
- Chong, A., Menberg, K., 2018. Guidelines for the Bayesian calibration of building energy models. *Energy and Buildings* 174, 527–547. <https://doi.org/10.1016/j.enbuild.2018.06.028>

- Coakley, D., Raftery, P., Keane, M., 2014. A review of methods to match building energy simulation models to measured data. *Renewable and Sustainable Energy Reviews* 37, 123–141. <https://doi.org/10.1016/j.rser.2014.05.007>
- Cukier, R.I., Fortuin, C.M., Shuler, K.E., Petschek, A.G., Schaibly, J.H., 1973. Study of the sensitivity of coupled reaction systems to uncertainties in rate coefficients. I Theory. *The Journal of Chemical Physics* 59, 3873–3878. <https://doi.org/10.1063/1.1680571>
- Fabrizio, E., Monetti, V., 2015. Methodologies and Advancements in the Calibration of Building Energy Models. *Energies* 8, 2548–2574. <https://doi.org/10.3390/en8042548>
- Faggianelli, G.A., Mora, L., Merheb, R., 2017. Uncertainty quantification for Energy Savings Performance Contracting: Application to an office building. *Energy and Buildings* 152, 61–72. <https://doi.org/10.1016/j.enbuild.2017.07.022>
- Gelman, A., Rubin, D.B., 1992. Inference from Iterative Simulation Using Multiple Sequences. *Statist. Sci.* 7. <https://doi.org/10.1214/ss/1177011136>
- Gill, Z.M., Tierney, M.J., Pegg, I.M., Allan, N., 2010. Low-energy dwellings: the contribution of behaviours to actual performance. *Building Research & Information* 38, 491–508. <https://doi.org/10.1080/09613218.2010.505371>
- González-Torres, M., Pérez-Lombard, L., Coronel, J.F., Maestre, I.R., Yan, D., 2022. A review on buildings energy information: Trends, end-uses, fuels and drivers. *Energy Reports* 8, 626–637. <https://doi.org/10.1016/j.egyr.2021.11.280>
- Harshalatha, Patil, S., Kini, P.G., 2024. Calibration of simulation model to analyze hospital building energy performance. *Energy and Buildings* 313, 114242. <https://doi.org/10.1016/j.enbuild.2024.114242>
- Herbinger, F., Vandenhof, C., Kummert, M., 2023. Building energy model calibration using a surrogate neural network. *Energy and Buildings* 289, 113057. <https://doi.org/10.1016/j.enbuild.2023.113057>
- Hillen, M., Schönfeldt, P., Groesdonk, P., Hoffschmidt, B., 2024. Integration of a Europe-wide public building database with retrofit strategies and a thermal inertia model into an open-source optimization framework. *IOP Conf. Ser.: Earth Environ. Sci.* 1363, 012013. <https://doi.org/10.1088/1755-1315/1363/1/012013>
- Hong, T., Langevin, J., Sun, K., 2018. Building simulation: Ten challenges. *Build. Simul.* 11, 871–898. <https://doi.org/10.1007/s12273-018-0444-x>
- Hopfe, C.J., Hensen, J.L.M., 2011. Uncertainty analysis in building performance simulation for design support. *Energy and Buildings* 43, 2798–2805. <https://doi.org/10.1016/j.enbuild.2011.06.034>
- Hou, D., Hassan, I.G., Wang, L., 2021. Review on building energy model calibration by Bayesian inference. *Renewable and Sustainable Energy Reviews* 143, 110930. <https://doi.org/10.1016/j.rser.2021.110930>
- Hou, D., Zhan, D., Wang, L., Hassan, I.G., Sezer, N., 2023. Development and performance assessment of a new opensource Bayesian inference R platform for building energy model calibration. *Discov Mechanical Engineering* 2, 19. <https://doi.org/10.1007/s44245-023-00027-2>
- Jacques, J., Lavergne, C., Devictor, N., 2006. Sensitivity analysis in presence of model uncertainty and correlated inputs. *Reliability Engineering & System Safety* 91, 1126–1134. <https://doi.org/10.1016/j.res.2005.11.047>

- Kristensen, M.H., Petersen, S., 2016. Choosing the appropriate sensitivity analysis method for building energy model-based investigations. *Energy and Buildings* 130, 166–176. <https://doi.org/10.1016/j.enbuild.2016.08.038>
- Lewis, A.L., Smith, R.C., Williams, B.J., 2017. Bayesian model calibration on active subspaces, in: 2017 American Control Conference (ACC). Presented at the 2017 American Control Conference (ACC), IEEE, Seattle, WA, USA, pp. 3165–3170. <https://doi.org/10.23919/ACC.2017.7963434>
- Macdonald, I., 2009. Comparison of sampling techniques on the performance of Monte Carlo based sensitivity analysis, in: IBPSA Building Simulation 09. Scotland.
- New Buildings Institute, 2008. Energy performance of LEED-NC buildings (Final report).
- Olu-Ajayi, R., Alaka, H., Egwim, C., Grishikashvili, K., 2024. Comprehensive Analysis of Influencing Factors on Building Energy Performance and Strategic Insights for Sustainable Development: A Systematic Literature Review. *Sustainability* 16, 5170. <https://doi.org/10.3390/su16125170>
- Ramos Ruiz, G., Fernández Bandera, C., Gómez-Acebo Temes, T., Sánchez-Ostiz Gutierrez, A., 2016. Genetic algorithm for building envelope calibration. *Applied Energy* 168, 691–705. <https://doi.org/10.1016/j.apenergy.2016.01.075>
- Remmen, P., 2021. Automated calibration of non-residential urban building energy modeling; 1. Auflage, Dissertation. RWTH Aachen University. <https://doi.org/10.18154/RWTH-2022-03245>
- Riddle, M., Muehleisen, R., 2014. A Guide to Bayesian Calibration of Building Energy Models, in: SimBuild Conference. Presented at the Proceedings of ASHRAE/IBPSA-USA Building Simulation Conference, ASHRAE/IBPSA-USA, pp. 276–283.
- Risch, S., Remmen, P., Müller, D., 2021. Influence of data acquisition on the Bayesian calibration of urban building energy models. *Energy and Buildings* 230, 110512. <https://doi.org/10.1016/j.enbuild.2020.110512>
- Rivalin, L., Stabat, P., Marchio, D., Caciolo, M., Hopquin, F., 2018. A comparison of methods for uncertainty and sensitivity analysis applied to the energy performance of new commercial buildings. *Energy and Buildings* 166, 489–504. <https://doi.org/10.1016/j.enbuild.2018.02.021>
- Robertson, J.J., Polly, B.J., Collis, J.M., 2015. Reduced-order modeling and simulated annealing optimization for efficient residential building utility bill calibration. *Applied Energy* 148, 169–177. <https://doi.org/10.1016/j.apenergy.2015.03.049>
- Saltelli, A., 2002. Making best use of model evaluations to compute sensitivity indices. *Computer Physics Communications* 145, 280–297. [https://doi.org/10.1016/S0010-4655\(02\)00280-1](https://doi.org/10.1016/S0010-4655(02)00280-1)
- Saltelli, A., Annoni, P., Azzini, I., Campolongo, F., Ratto, M., Tarantola, S., 2010. Variance based sensitivity analysis of model output. Design and estimator for the total sensitivity index. *Computer Physics Communications* 181, 259–270. <https://doi.org/10.1016/j.cpc.2009.09.018>
- Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., Saisana, M., Tarantola, S., 2007. Global Sensitivity Analysis. The Primer, 1st ed. Wiley. <https://doi.org/10.1002/9780470725184>

- Saltelli, A., Sobol', I.M., 1995. About the use of rank transformation in sensitivity analysis of model output. *Reliability Engineering & System Safety* 50, 225–239.
[https://doi.org/10.1016/0951-8320\(95\)00099-2](https://doi.org/10.1016/0951-8320(95)00099-2)
- Saltelli, A., Tarantola, S., Campolongo, F., Ratto, M., 2002. *Sensitivity Analysis in Practice: A Guide to Assessing Scientific Models*, 1st ed. Wiley.
<https://doi.org/10.1002/0470870958>
- Saltelli, A., Tarantola, S., Chan, K.P.-S., 1999. A Quantitative Model-Independent Method for Global Sensitivity Analysis of Model Output. *Technometrics* 41, 39–56.
<https://doi.org/10.1080/00401706.1999.10485594>
- Santamouris, M., Vasilakopoulou, K., 2021. Present and Future Energy Consumption of Buildings: Challenges and Opportunities towards Decarbonisation. *e-Prime* 100002.
<https://doi.org/10.1016/j.prime.2021.100002>
- Shen, C., Lee, S., Lee, C.-G., Lai, J., 2023. A novel framework for Bayesian calibration of building energy models with sub-hourly building operational data. Presented at the 2023 Building Simulation Conference. <https://doi.org/10.26868/25222708.2023.1418>
- Sobol', I.M., 2001. Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates. *Mathematics and Computers in Simulation* 55, 271–280.
[https://doi.org/10.1016/S0378-4754\(00\)00270-6](https://doi.org/10.1016/S0378-4754(00)00270-6)
- Sobol', I.M., 1967. On the distribution of points in a cube and the approximate evaluation of integrals. *USSR Computational Mathematics and Mathematical Physics* 7, 86–112.
[https://doi.org/10.1016/0041-5553\(67\)90144-9](https://doi.org/10.1016/0041-5553(67)90144-9)
- Sun, K., Hong, T., Taylor-Lange, S.C., Piette, M.A., 2016. A pattern-based automated approach to building energy model calibration. *Applied Energy* 165, 214–224.
<https://doi.org/10.1016/j.apenergy.2015.12.026>
- Tian, W., Heo, Y., De Wilde, P., Li, Z., Yan, D., Park, C.S., Feng, X., Augenbroe, G., 2018. A review of uncertainty analysis in building energy assessment. *Renewable and Sustainable Energy Reviews* 93, 285–301. <https://doi.org/10.1016/j.rser.2018.05.029>
- Tresidder, E., Zhang, Y., Forrester, A., 2012. Acceleration of Building Design Optimisation Through the Use of Kriging Surrogate Models, in: *Proceedings of BSO Conference 2012*. Presented at the 1st Conference of IBPSA-England, IBPSA Publications.
- University of Calgary, Canada, Muslim, S.A., 2021. EnergyPlus-Towards the Selection of Right Simulation Tool for Building Energy and Power Systems Research. *JEPT* 03, 1–1. <https://doi.org/10.21926/jept.2103034>
- Wang, Z., Wang, Y., Zeng, R., Srinivasan, R.S., Ahrentzen, S., 2018. Random Forest based hourly building energy prediction. *Energy and Buildings* 171, 11–25.
<https://doi.org/10.1016/j.enbuild.2018.04.008>
- Wei, Y., Zhang, X., Shi, Y., Xia, L., Pan, S., Wu, J., Han, M., Zhao, X., 2018. A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews* 82, 1027–1047.
<https://doi.org/10.1016/j.rser.2017.09.108>
- Wilke, C., Brandt, D., Kaul-Gothe, W., Kriegel, M., Brandt, S., Nytsch-Geusen, C., Küster-Inderfurth, A., Reiche, S., 2020. *Digitales Analyse-Tool für Energetische Sanierungsfahrpläne: Schlussbericht (Endbericht)*. Berlin.

- Xiu, D., Karniadakis, G.E., 2002. The Wiener--Askey Polynomial Chaos for Stochastic Differential Equations. *SIAM J. Sci. Comput.* 24, 619–644.
<https://doi.org/10.1137/S1064827501387826>
- Zhao, H., Magoulès, F., 2012. A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews* 16, 3586–3592.
<https://doi.org/10.1016/j.rser.2012.02.049>

Anhang

Table 1-B Zusammenfassung einiger Schlüsselfaktoren aus der Literaturstudie

Titel	Validation of a Bayesian-based method for defining residential archetypes in urban building energy models	Bayesian Calibration at the Urban Scale: a case study on a large residential heating demand application in Amsterdam	Calibration of building Energy Models for Retrofit Analysis under uncertainty
Autor	Sokol J, Cerezo DVC, Reinhart CF	Wang Ch.K, Tindemans S, Miller C, Agugiaro G, Stoter J	Heo Y, Choudhary R, Augenbroe G.A
Umfang der Studie	Klassifizierung der Archetypen und Vorhersage des Energieverbrauchs der Bestände	Validierung und Vorhersage des Energieverbrauchs von Lagerbeständen	Validierung des Energieverbrauchs und Vorhersage des Nachrüstungseffekts
Skala der Gebäude	verschiedene Gebäudebestände	verschiedene Gebäudebestände	Einzelgebäude
Typ des Gebäudes	Wohngebäude	Wohngebäude	Bürogebäude
Datentyp	Elektrizitätsverbrauch, Gasverbrauch	Gasverbrauch	Gasverbrauch
Datenaufösung	monatliche Daten (12 Monate)	jährliche Daten (10 Jahre)	monatliche Daten (36 Monate)
Sensitivitätsanalyse	empirische Annahme	Morris-Methode mit einem Monte-Carlo-Ansatz. (Ausgeführt mit einem Python-Skript und der externen Bibliothek SALib) Für die Sensitivitätsanalyse wird ein kubisches Gebäude eingerichtet.	Morris-Method (mit Simlab)
Kalibrierungsparameter	Infiltration, Thermostat-Sollwerte, Belegungsdichte, Steckdosenlast und Beleuchtungsleistungsdichte, Warmwasserdurchfluss	Minimale Thermostateinstellung, Inditrierungsrate.	Lüftungsschnittpunkt C, Innenraum T, Infiltrationsrate, Lüftungsabflusskoeffizient, Leistungsdichte, Fenster U-Wert, Heizungsverlust
Vorherige Wahrscheinlichkeitsverteilung	Gleichmäßige Wahrscheinlichkeitsverteilung.	Gleichmäßige Wahrscheinlichkeitsverteilung.	Dreiecks-Wahrscheinlichkeitsverteilung
Gebäude-Energiesimulations-tool	EnergyPlus	CitySim	EnergyPlus & Normative Energy Model

Tabelle 1-C Zusammenfassung einiger Schlüsselfaktoren aus der Literaturstudie

Titel	Comparison of four building archetype characterization methods in urban building energy modeling (UBEM): A residential case study in Kuwait City	Bayesian-Emulator based parameter identification for calibrating energy models for existing buildings	Bayesian calibration of building energy models with large datasets
Autor	Cerezo C, Sokol J, AlKhaled S, Reinhart Ch, Al-Mumin A, Hajiah A	Kang Y, Krarti M	Chong A, Lam K.P., Pozzi M, Yang J
Umfang der Studie	Validierung des Energieverbrauchs der Bestände	Validierung der Bayes'schen Kalibrierung an einem Bürogebäude	Verbesserung der Bayes'schen Kalibrierung für eine größere Datenmenge (stündlich statt monatlich)
Skala der Gebäude	verschiedene Gebäudebestände	Einzelgebäude	Einzelgebäude
Typ des Gebäudes	Wohngebäude	Nichtwohngebäude	Nichtwohngebäude
Datentyp	Intensität der Energienutzung. Gemessene Daten für jedes Gebäude.	Gesamtenergieverbrauch	Energieverbrauch einer wassergekühlten Kältemaschine. Energieverbrauch des Kühlsystems.
Datenauflösung	jährliche Daten (1 Jahr)	monatliche Daten	stündliche Daten (720 Stunden)
Sensitivitätsanalyse	Die Parameter werden mit Hilfe von Fachwissen und unter Anwendung von $\pm 15\%$ Variation der Modellparameter für ein durchschnittliches Gebäude ausgewählt.	Lokale Sensitivitätsanalyse	Morris-Method (Rsensitivity package)
Kalibrierungs-parameter	Belegungsbezogene Parameter: Kühlungs-Sollwerttemperatur, Spitzenwert der installierten Beleuchtungsleistung, durchschnittlicher Spitzenwert der Belegungsdichte, Steckdosenlasten. Latin Hyper Cube für probabilistische Parametererfassung	Effizienz der Heizungsanlage, Gerätedichte, Infiltration	Relevante Parameter des Kältesystems
Vorherige Wahrscheinlichkeitsverteilung	Gleichmäßige Wahrscheinlichkeitsverteilung.	Gaußsche Verteilungsfunktion mit Konfidenzniveau	-
Gebäude-Energiesimulations-tool	EnergyPlus	Emulator wird verwendet	TRNYS, EnergyPlus

Tabelle 1-D Zusammenfassung einiger Schlüsselfaktoren aus der Literaturstudie

Titel	Narrowing uncertainties in forecasting urban building energy demand	Automated Calibration of Non-Residential Urban Building Energy Model in	Calibration of Dynamic Building Energy Models with Multiple Responses Using Bayesian Inference and Linear Regression Models
Autor	Gholami M, Torreggiani D, Tassinari P, Barbaresi A	Remmen P.	Li Q, Gu L, Augenbroe G, Wu C.F.J., Brown J
Umfang der Studie	Validierung des Energieverbrauchs der Bestände	Validierung der Bayes'schen Kalibrierung mit einem Emulator und mit 22 realen Gebäuden	Validierung des Energieverbrauchs
Skala der Gebäude	verschiedene Gebäudebestände	verschiedene Gebäudebestände	Einzelgebäude
Typ des Gebäudes	Wohngebäude	Nichtwohngebäude	Nichtwohngebäude
Datentyp	Intensität der Energienutzung (Strom- und Gasverbrauch)	Wärmeenergieverbrauch	Kaltwasser- und Stromverbrauch
Datenaufösung	jährliche Daten (1 Jahr)	stündliche Daten (17 520 Stunden)	15 Minuten Auflösung (70 000 Daten)
Sensitivitätsanalyse	Standardisierter Regressionskoeffizient und die Bedeutung der Random Forest-Variable (Rsensitivity package)	Morris-Method	-
Kalibrierungs-parameter	Leistungsdichte der Geräte, Kühlsollwert, Heizsollwert, Personendichte, Warmwasserverbrauch, Infiltrationsrate	Nachttemperatur, Infiltrationsrate, Fensterflächenkoeffizient	Kühlungs-Sollwert, Belegungsdichte, Außenluftvolumenstrom
Vorherige Wahrscheinlichkeitsverteilung	-	Gleichmäßige und dreieckige Wahrscheinlichkeitsverteilung	Dreiecks-Wahrscheinlichkeitsverteilung.
Gebäude-Energiesimulations-tool	EnergyPlus	Reduced Order Model from Modelica	OpenStudio, EnergyPlus

Tabelle 1-E Zusammenfassung einiger Schlüsselfaktoren aus der Literaturstudie

Titel	A methodology for calibration of building energy models at district scale using clustering and surrogate techniques	Urban-scale Energy Modeling of Food Supermarket Considering Uncertainty
Autor	Tardioli G, Narayan A, Kerrigan R, Oates M, O' Donnell J, Finn D.P.	Yamaguchi Y, Suzuki Y, Choudhary R, Booth A, Shimoda Y
Umfang der Studie	Validierung des Energieverbrauchs verschiedene Gebäudebestände (326 Gebäude - 14 Cluster)	Validierung des Energieverbrauchs Lagerbestand (35 Gebäude - 1 Archetyp)
Skala der Gebäude		
Typ des Gebäudes	Alle Typen	Supermärkte
Datentyp	Gebäudeenergieverbrauch (Heizung + Warmwasser) Gemessene Daten im Durchschnitt der Nachbarschaft.	Intensität der Energienutzung
Datenauflösung	Durchschnittlich pro Jahr (1 Jahr)	Wöchentlich, monatlich, jährlich
Sensitivitätsanalyse	-	Faktorielle Stichprobenmethode
Kalibrierungs-parameter	Beleuchtungsstärke, Belegungsdichte, Infiltrationen, Heizungssollwert, Warmwasserverbrauch, Effizienz des Warmwassersystems	COP des Kühlschranks, Länge des Schrankes, Beleuchtungsstärke, Luftgeschwindigkeit des Luftvorhangs
Vorherige Wahrscheinlichkeitsverteilung	-	Dreiecks-Wahrscheinlichkeitsverteilung.
Gebäude-Energiesimulations-tool	JE+, EnergyPlus	-