

**KI-gestütztes adaptives Modell
zur Optimierung der Lebensdauerprognosen von Bauelementen un-
ter Berücksichtigung spezifischer Einflussfaktoren**

Vom Fachbereich Bauingenieurwesen der
Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau
Fachgebiet Baubetrieb und Bauwirtschaft
zur Verleihung des akademischen Grades

Doktor-Ingenieur (Dr.-Ing.)

genehmigte

Dissertation

von

Daniel Ralf Jonathan Walter, M. Sc.

| | |
|----------------------|-----------------------------------|
| 1. Berichterstatter: | Prof. Dr.-Ing. Karsten Körkemeyer |
| 2. Berichterstatter: | Prof. Dr.-Ing. Christian Glock |
| Vorsitzender: | Prof. Dr.-Ing. Wilko Manz |
| Tag der Abgabe: | 21.06.2024 |
| Tag der Disputation: | 23.10.2024 |

Kaiserslautern, 2024

(DE - 386)

Vorwort

Ich widme diese Arbeit meinem verstorbenen Vater Manfred Walter. Er war nicht nur ein aufmerksamer, guter Vater, sondern auch Dipl. Wirtschaftsingenieur mit großer Leidenschaft für seine Arbeit.

Für seine unendliche Geduld und Hingabe, mit der er mir die Freude an der Mathematik und die Fähigkeiten für diese vermittelt hat, bin ich ihm unendlich dankbar.

Leider konnte er den Tag meiner Abgabe nicht mehr miterleben.

„Dennoch bleibe ich stets an Dir; denn Du hältst mich bei meiner rechten Hand, Du leitest mich nach deinem Rat und nimmst mich am Ende mit Ehren an.“

Psalm 73:23-24

Manfred Walter 11.11.1956 – 21.06.2023

Diese Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Fachgebiet für Baubetrieb und Bauwirtschaft der Rheinland-Pfälzischen Technische Universität Kaiserslautern-Landau.

Sie ist das Resultat der wissenschaftlichen Aufarbeitung meiner Mitarbeit an dem Projekt Operationalisierung mittels künstlicher Intelligenz bei Gebäuden (OPKI) bei dem Unternehmen LifeCycle-Competence GmbH & Co. KG. Dabei gilt großer Dank meinen beiden Kollegen Thomas Häßel und Ingo Besenbruch.

Außerdem danke ich meiner Familie und meiner Freundin Joana, die mich durch alle Höhen und Tiefen meiner Doktorandenzeit begleitet haben.

Ein besonderer Dank gilt Prof. Dr.-Ing. Karsten Körkemeyer, der mich in den Jahren am Lehrstuhl immer gut betreut und mir, wenn erforderlich, den Rücken freigehalten hat.

Zusammenfassung

Die Thematik der Lebensdauern im Bauwesen gewinnt durch die verstärkte Nachfrage nach Ökobilanzen und Lebenszykluskostenberechnungen zunehmend an Bedeutung. Nachhaltiges Bauen und nachhaltiges Wirtschaften waren noch nie so aktuell wie heute. Über den gesamten Lebenszyklus einer Immobilie fallen neben den Errichtungskosten eine Vielzahl weiterer Kosten an.

Im Gegensatz zu den meisten dieser Kosten lassen sich die Kosten für die Leistung Instandhaltung (Instandhaltungskosten) nur unpräzise und mit großem Aufwand planen.

Insbesondere in Kommunen, die über einen großen und breit gestreuten Immobilienbestand verfügen, ist die Planung dieser Instandhaltungen schwierig. Möglichst genaue Informationen über die Lebensdauern der Bauteile eines Gebäudes sind eine Grundvoraussetzung für die Planung der Instandhaltungsstrategie und ein notwendiger Berechnungsparameter sowohl für LCC¹- als auch für LCA²-Betrachtungen.

Statt regelmäßiger und oft sehr zeitaufwändiger Begehungen jedes einzelnen Objekts werden häufig Näherungsverfahren verwendet, die statistische Lebensdauern zur Ermittlung der Bauteilzustände nutzen.

Die Qualität der Ergebnisse dieser Verfahren hängt direkt von der Qualität der verwendeten Referenzlebensdauern ab. Darüber hinaus ist zu berücksichtigen, dass eine Vielzahl von Einflussfaktoren auf die Lebensdauer eines Bauteils einwirken und diese verkürzen oder verlängern.

In Deutschland wird hierfür bisher die Faktorenmethode nach DIN ISO 15686 angewendet.

Die Berechnung der Lebensdauer nach ISO 15686 unter Anwendung der Faktorenmethode stellt in der Praxis eine anspruchsvolle Aufgabe dar, da die ISO 15686 in vielerlei Hinsicht Interpretationsspielraum und offene Fragen lässt.

Dies führt zu einer Vielzahl von Variablen bei der Bestimmung der Lebensdauer, was zu ungenauen Ergebnissen führen kann.

Diese Arbeit beschäftigt sich mit den Ungenauigkeiten und Problemen bei der Bestimmung von Bauteillebensdauern. Dabei wird exemplarisch für die Gebäudehülle ein KI-basierter Ansatz entwickelt, um individuelle Lebensdauerprognosen unter Berücksichtigung bestimmter Einflussfaktoren zu erstellen.

Das Ziel ist die Verbesserung der Genauigkeit von Lebensdauerprognosen für Bauteile und der darauf basierenden Kostenprognose für Instandsetzungen.

¹ Life Cycle Costing (dt.: Lebenszykluskostenrechnung)

² Life Cycle Assessments (dt.: Lebenszyklusanalyse bzw. Ökobilanz)

Abstract

The topic of lifetimes in construction is becoming increasingly important due to the increased demand for life cycle assessments and life cycle cost calculations. Sustainable construction and sustainable management have never been as topical as they are today. Over the entire life cycle of a property, a large number of costs are incurred in addition to the construction costs.

In contrast to most of these costs, the costs for the maintenance service (maintenance costs) can only be planned with great effort.

Especially in municipalities that have a large and widely dispersed real estate portfolio, planning these maintenance costs is difficult. The most accurate possible information on the lifetimes of a building's components is a basic prerequisite for planning the maintenance strategy and a necessary calculation parameter for both LCC³ and LCA⁴ considerations.

Instead of a regular inspection of each individual object, the determination of the specific service life based on corresponding methods for determining the age of building components is often resorted to here.

The quality of the results of these methods depends directly on the quality of the reference lifetimes used. Furthermore, it must be considered that a multitude of influencing factors affect the service life of a component and shorten or lengthen it.

In Germany, the factor method according to DIN ISO 15686 has been used for this purpose up to now.

Calculating the service life according to ISO 15686 using the factor method is a demanding task in practice, as ISO 15686 leaves room for interpretation and open questions in many respects.

This leads to a large number of variables in the determination of the service life, which can lead to inaccurate results.

This paper deals with the inaccuracies and problems in the determination of building component lifetimes. An AI-based approach is developed for the building envelope as an example in order to create individual service life forecasts taking into account certain influencing factors.

The aim is to improve the accuracy of service life forecasts for building components and the cost forecasts for repairs based on them.

³ Life Cycle Costing

⁴ Life Cycle Assessments

Inhaltsverzeichnis

| | |
|------------------------------------|----------|
| Vorwort | iii |
| Zusammenfassung | v |
| Abstract | vii |
| Inhaltsverzeichnis | ix |
| Abkürzungen | xv |
| 1 Einleitung | 1 |
| 1.1 Problemstellung und Motivation | 1 |
| 1.2 Zielsetzung | 6 |
| 1.3 Vorgehensweise | 7 |
| 2 Grundlagen | 9 |
| 2.1 Instandhaltung von Gebäuden | 9 |
| 2.1.1 Einführung | 9 |
| 2.1.2 Begriffserklärungen | 9 |
| 2.1.2.1 Abnutzung | 9 |
| 2.1.2.2 Abnutzungsgrenze | 9 |
| 2.1.2.3 Abnutzungsprognose | 9 |
| 2.1.2.4 Abnutzungsvorrat | 9 |
| 2.1.2.5 Ausfall | 10 |
| 2.1.2.6 Gebäudemanagement | 10 |
| 2.1.2.7 Instandhaltung | 12 |
| 2.1.2.8 Instandhaltungsstrategie | 14 |
| 2.1.2.9 Instandhaltungsziele | 15 |
| 2.1.2.10 Instandsetzung | 15 |
| 2.1.2.11 Inspektion | 15 |
| 2.1.2.12 Kostengruppen | 15 |
| 2.1.2.13 Lebensdauer | 16 |
| 2.1.2.14 Lebenszyklus | 16 |
| 2.1.2.15 Lebenszykluskosten | 17 |
| 2.1.2.16 Lebenszyklusphasen | 17 |
| 2.1.2.17 Lebenszyklus von Gebäuden | 18 |
| 2.1.2.18 Modernisierung | 18 |
| 2.1.2.19 Nutzungskosten | 18 |
| 2.1.2.20 Reparatur | 18 |
| 2.1.2.21 Sanierung | 19 |
| 2.1.2.22 Verbesserung | 19 |
| 2.1.2.23 Wartung | 19 |
| 2.1.3 Abgrenzung dieser Arbeit | 20 |

| | | |
|---------------|--|---|
| 2.2 | Lebensdauerermittlung von Bauteilen | 22 |
| 2.2.1 | Einführung | 22 |
| 2.2.2 | Aktueller Stand der Forschung | 23 |
| 2.2.3 | Norm ISO 15686 | 25 |
| 2.2.4 | Alterungsverhalten von Bauteilen | 26 |
| 2.2.5 | Zusammenfassung | 30 |
| 2.3 | Künstliche Intelligenz | 31 |
| 2.3.1 | Einführung | 31 |
| 2.3.1.1 | Abgrenzung von Machine Learning | 32 |
| 2.3.1.2 | Abgrenzung Deep Learning | 36 |
| 2.3.1.3 | Symbolische und Subsymbolische AI | 36 |
| 2.3.1.4 | Philosophische Betrachtung | 37 |
| 2.3.1.5 | Ergänzende Erläuterungen | 37 |
| 2.3.2 | AI-spezifische Problemdefinitionen | 38 |
| 2.3.2.1 | Einleitung | Fehler! Textmarke nicht definiert. |
| 2.3.2.2 | Clustering | 38 |
| 2.3.2.3 | Computer Vision und Bilderkennung | 38 |
| 2.3.2.4 | Erkennung von Anomalien | 39 |
| 2.3.2.5 | Klassifizierung | 39 |
| 2.3.2.6 | Optimierung | 40 |
| 2.3.2.7 | Regression | 40 |
| 2.3.2.8 | Verarbeitung natürlicher Sprache (NLP) | 41 |
| 2.3.3 | Machine Learning | 42 |
| 2.3.3.1 | System ML nach ISO/IEC 23053 | 43 |
| 2.3.3.1.1 (a) | Task (problem definition) | 43 |
| 2.3.3.1.2 (b) | Model | 44 |
| 2.3.3.1.3 (c) | Data | 44 |
| 2.3.3.1.4 (d) | Tools and techniques | 44 |
| 2.3.3.2 | Ansätze | 45 |
| 2.3.3.2.1 | Supervised Learning | 46 |
| 2.3.3.2.2 | Unsupervised Learning | 47 |
| 2.3.3.2.3 | Reinforcement Learning | 48 |
| 2.3.3.3 | Datenaufbereitung | 49 |
| 2.3.3.4 | Künstliche Neuronale Netze | 54 |
| 2.3.3.5 | Deep Learning | 70 |
| 2.3.3.6 | Lernkurve | 71 |
| 2.3.3.7 | Hyperparameter | 73 |
| 2.3.3.8 | Bibliotheken | 74 |
| 3 | Analyse verschiedener Verfahren zur Lebensdauerermittlung | 77 |

| | | |
|----------|---|------------|
| 3.1 | Einleitung | 77 |
| 3.2 | Kennwertmethode | 77 |
| 3.3 | Referenzfaktorenmethode von Tomm, Rentmeister und Finke | 79 |
| 3.4 | Faktorenmethode nach der ISO 15686 | 80 |
| 3.5 | Ansatz von Ritter | 83 |
| 3.6 | Ansatz von Bahr und Lennerts | 84 |
| 4 | Bauteile im Bauwesen nach DIN 276 | 86 |
| 4.1 | Einleitung | 86 |
| 4.2 | Erweiterung der Kostengruppenstruktur | 88 |
| 5 | Einflussfaktoren auf die Lebensdauern von Bauelementen | 91 |
| 5.1 | Einleitung | 91 |
| 5.2 | Materielle Einflussfaktoren | 92 |
| 5.2.1 | Einleitung | 92 |
| 5.2.2 | Bauteilqualität | 93 |
| 5.2.3 | Planungsqualität | 93 |
| 5.2.4 | Ausführungsqualität | 94 |
| 5.2.5 | Umwelt (innen) | 94 |
| 5.2.6 | Umwelt (außen) | 95 |
| 5.2.6.1 | Erschütterung | 97 |
| 5.2.6.2 | Feuchtigkeit | 100 |
| 5.2.6.3 | Hagel | 101 |
| 5.2.6.4 | Luftverschmutzung | 102 |
| 5.2.6.5 | Schnee | 103 |
| 5.2.6.6 | Strahlung | 105 |
| 5.2.6.7 | Temperatur | 107 |
| 5.2.6.8 | Wind | 108 |
| 5.2.7 | Nutzungszustand | 109 |
| 5.2.8 | Instandhaltungsqualität | 110 |
| 5.3 | Immaterielle Einflussfaktoren | 111 |
| 6 | Auswahl der Bauteile (Gebäudehülle) | 113 |
| 7 | Auswahl der Orte | 117 |
| 7.1 | Einleitung | 117 |
| 7.2 | Standort 1 in Rheinland-Pfalz | 119 |
| 7.3 | Standort 2 in Baden-Württemberg | 119 |
| 7.4 | Standort 3 in Rheinland-Pfalz | 120 |
| 7.5 | Standort 4 in Rheinland-Pfalz | 121 |
| 7.6 | Zusammenfassung | 122 |
| 8 | Datengrundlage | 125 |

| | | |
|-----------|---|------------|
| 8.1 | Dysisko-Datenbank | 125 |
| 8.2 | Datenaufbereitung | 127 |
| 8.2.1 | Exploring | 128 |
| 8.2.2 | Data wrangling | 129 |
| 8.2.3 | Cleaning | 132 |
| 8.2.4 | Imputation | 134 |
| 8.2.5 | Normalisation and scaling | 134 |
| 8.2.6 | Dataset composition | 135 |
| 8.2.6.1 | Allgemeines | 135 |
| 8.2.6.2 | Verknüpfung der Bauelemente mit den äußeren Umweltbedingungen | 136 |
| 8.2.6.3 | Zusammenführung der Bauelemente | 137 |
| 8.2.6.4 | One-Hot Kodierung | 137 |
| 8.2.7 | Dataset splitting | 139 |
| 8.2.8 | Labeling | 139 |
| 8.3 | Erzeugung synthetischer Daten | 139 |
| 8.4 | Grafische Datenanalyse | 144 |
| 9 | Modellentwicklung | 151 |
| 9.1 | Einleitung | 151 |
| 9.2 | Theoretisches Modell | 151 |
| 9.2.1 | Einleitung | 151 |
| 9.2.2 | Komponenten A und B | 152 |
| 9.2.3 | Komponente C | 152 |
| 9.2.4 | Komponente D | 152 |
| 9.2.5 | Zerfallsrate | 153 |
| 9.3 | Neuronales Modell | 155 |
| 9.3.1 | Einleitung | 155 |
| 9.3.2 | Datenvorbereitung | 157 |
| 9.3.3 | Architektur | 159 |
| 9.3.3.1 | KerasTuner | 161 |
| 9.3.4 | Evaluation | 162 |
| 9.4 | Prototyp | 165 |
| 10 | Evaluation der Ergebnisse | 171 |
| 10.1 | Einleitung | 171 |
| 10.2 | Kritische Betrachtung | 171 |
| 10.3 | Auswertung | 173 |
| 10.3.1 | Einleitung | 173 |
| 10.3.2 | Tragende Außenwände (3310) | 177 |
| 10.3.3 | Außenfenster (3341) | 178 |
| 10.3.4 | Außentüren (3342) | 180 |

| | | |
|-----------|---|------------|
| 10.3.5 | Außenwandbekleidung Putz (3351) | 181 |
| 10.3.6 | Elementierte Außenwandkonstruktionen (3370) | 183 |
| 10.3.7 | Dachöffnungen (3620) | 184 |
| 10.3.8 | Flachdachabdichtung (3631) | 186 |
| 10.3.9 | Dachdeckung (3632) | 187 |
| 10.3.10 | Attikaabdeckung (3633) | 189 |
| 10.3.11 | Entwässerung (3634) | 190 |
| 11 | Zusammenfassung und Fazit | 193 |
| 12 | Ausblick | 197 |
| 13 | Anhang | 201 |
| 13.1 | Anhang A | 201 |
| 13.2 | Anhang B | 214 |
| 13.3 | Anhang C | 225 |
| 13.4 | Anhang D | 245 |
| 14 | Abbildungsverzeichnis | 251 |
| 15 | Tabellenverzeichnis | 257 |
| 16 | Literatur | 259 |

Abkürzungen

| | |
|---------|--|
| AfA | Absetzung für Abnutzung |
| AI | Artificial Intelligence |
| ANN | Artificial Neural Networks |
| ARGEBAU | Arbeitsgemeinschaft der Bauminister der Länder |
| BBSR | Bundesinstitut für Bau-, Stadt- und Raumforschung |
| BMWSB | Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen |
| BPD | Business Process Diagram |
| BPMN | Business Process Model and Notation |
| BTE | Bund Technischer Experten e.V., Bund Technischer Experten |
| CSV | Comma separated values |
| DENA | Deutschen Energie-Agentur |
| DIN | German Institute for Standardization |
| DL | Deep Learning, Deep Learning |
| EStG | Einkommensteuergesetz |
| GM | Gebäudemanagement |
| HDF5 | Hierarchical Data Format, Version 5 |
| IEMB | Institut für Erhaltung und Modernisierung von Bauwerken e.V. |
| IGM | Infrastrukturelles Gebäudemanagement |
| IR | Infrarotstrahlung (engl.: infrared) |
| ISO | International Organization for Standardization |
| KG | Kostengruppe |
| KGM | Kaufmännisches Gebäudemanagement |
| KI | Künstlichen Intelligenz |
| LCA | Life Cycle Assessments |
| LCC | Life Cycle Costing |
| MAE | Mean Absolute Error |
| MAPE | Mean Absolute Percentage Error |
| ML | Machine Learning |
| MSE | Mean Squared Error |

| | |
|------------|--|
| OPKI | Operationalisierung mittels künstlicher Intelligenz bei Gebäuden |
| RWA..... | Rauch- und Wärmeabzugsanlage |
| SGD | stochastic gradient descent |
| SPSS | Statistical Package for the Social Sciences |
| TGM..... | Technisches Gebäudemanagement |
| UV..... | Ultraviolettstrahlung (engl.: ultraviolet) |
| VIS..... | sichtbares Licht (engl.: visible radiation) |

1 Einleitung

1.1 Problemstellung und Motivation

Die Thematik Lebensdauern im Bauwesen gewinnt durch die erhöhte Nachfrage an Ökobilanzierungen und Lebenszykluskostenberechnungen an erheblicher Bedeutung. Nachhaltiges Bauen sowie nachhaltiges Wirtschaften stand noch nie zuvor so im Fokus wie aktuell. Über den gesamten Lebenszyklus einer Immobilie fallen neben den Errichtungskosten eine Vielzahl weiterer Kosten an, deren möglichst genaue Kenntnis und zeitliche Verteilung über den Lebenszyklus eines Gebäudes für ökonomische und ökologische Betrachtungen relevant sind. Die kumulierten Kosten, die für ein Gebäude über den gesamten Lebenszyklus anfallen, werden als Lebenszykluskosten bezeichnet. Bei einem Betrachtungszeitraum von 70 Jahren repräsentieren die ursprünglichen Errichtungskosten (diskontiert) lediglich 10,7 % [1] (Bürogebäude) beziehungsweise 21,1 % [1] (Wohnimmobilien) dieser Lebenszykluskosten. Eine grafische Illustration der Kostenverteilung bei Wohnimmobilien, in Anlehnung an den Forschungsbericht von Art und Pfeiffer [2] von 2004, kann der Abbildung 1 entnommen werden.




Abbildung 1: Lebenszykluskosten von Wohnimmobilien (Quelle: eigene Darstellung nach [2])

Die Abbildung 1 macht deutlich, dass die Kosten, die während des Betriebs einer Immobilie anfallen, die Baukosten signifikant dominieren.

Diese sogenannten Nutzungskosten lassen sich in einzelne Leistungsbereich unterteilen, welche sich nochmals in eigene Leistungen untergliedern lassen (vgl. [3]). Manche dieser Leistungen, wie beispielsweise die Ver- und Entsorgung, verursachen regelmäßige und vorhersehbare Kosten, welche mit einigen wenigen Kennzahlen für jede Immobilien ermittelt werden können. Im Gegensatz dazu lassen sich die Kosten für die Leistung Instandhaltung (Instandhaltungskosten) nur mit einem großen Aufwand terminieren und sind auch individuell für jede einzelne Immobilie zu ermitteln. Zu der Leistung der Instandhaltung zählt neben dem Warten und Inspizieren auch das Instandsetzen [4].

Gerade in Kommunen, die über ein großes und breit aufgestelltes Immobilienportfolio verfügen, fällt die Planung dieser Instandsetzungen schwer. Neben den zu ermittelnden Instandsetzungskosten, für die Einplanung in den Haushalt, müssen Instandsetzungen zum richtigen Zeitpunkt durchgeführt werden. Der richtige Zeitpunkt definiert sich dabei in Abhängigkeit von der gewählten Instandsetzungsstrategie des Instandhaltungsmanagements. Instandsetzungsstrategien werden in die präventive (vor Ausfall) und die korrektive Instandhaltung (nach Ausfall) nach der DIN 13306 differenziert [5]. Aus ökonomischer Sicht hat eine zu frühe oder zu späte Instandsetzung negative Auswirkungen. Setzt man ein Bauteil zu früh instand, ist der Wertverlust erfahrungsgemäß höher als bei einer Instandsetzung nahe dem Ausfallzeitpunkt [6]⁵. Werden Instandsetzungsmaßnahmen zu spät durchgeführt, kann dies dazu führen, dass die Schäden nicht mehr instandgesetzt werden können und das Bauteil teuer ersetzt werden muss. Außerdem besteht die Gefahr von Folgeschäden an benachbarten Bauteilen, wenn diese ihre Funktion nicht mehr erfüllen.

Möglichst präzise Informationen über die Lebensdauern von Bauteilen eines Gebäudes sind für die Planung der Instandsetzungsstrategie eine Grundvoraussetzung und sowohl für LCC⁶- als auch LCA⁷-Betrachtungen ein notwendiger Berechnungsparameter. Der Begriff der Lebensdauer definiert sich hierbei nicht als deterministische Größe, sondern als Wert mit einer verknüpften Eintrittswahrscheinlichkeit. Nachteilig ist, dass statistisch abgesicherte Aussagen über die Lebensdauer von Bauteilen eine aufwändige Auswertung von Lebensdauerdaten voraussetzen [7]. Eine Vielzahl von Einflussfaktoren wirken dabei auf die Lebensdauer eines Bauteiles ein und verkürzen oder verlängern diese.

Dabei muss zwischen der technischen und der wirtschaftlichen Lebensdauer, welche sich meist signifikant unterscheiden, differenziert werden. Das Ende der technischen Lebensdauer ist erreicht, wenn die vorgesehene Funktion und Nutzbarkeit eines Bauteiles nicht mehr erfüllt werden kann sowie die Kosten für eine Erhaltung die Kosten eines vollständigen Ersatzes und Herstellung eines neuen Bauteiles übersteigen. Die wirtschaftliche Lebensdauer (vgl. Kapitel 2.1.2.13) hingegen ist viel mehr von den ökonomischen Randbedingungen abhängig [8].

Bei der Verwendung des Begriffes Lebensdauer ist in dieser Arbeit ausschließlich die technische Lebensdauer gemeint.⁸

Deutschlands 11.116 Kommunen verfügen laut der Deutschen Energie-Agentur (Abkürzung: DENA) über schätzungsweise 186.000 öffentliche Gebäude [9]. Für eine präzise Instandhaltungsstrategie für diese Gebäude muss die öffentliche Hand damit bei jedem dieser Gebäude den aktuellen Stand der einzelnen Bauelemente kennen, damit entschieden werden kann, welches Gebäude bei der Instandhaltung priorisiert werden muss, und um zu kalkulieren, welche Kosten zu welchem Zeitpunkt für die Instandhaltungsmaßnahmen in den Haushalt eingeplant werden müssen. Erfahrungsgemäß wird hier, statt auf die regelmäßige Begehung eines

⁵ Schröder betrachtet die Entwertung von Bauteilen bei Sanierungen. Diese Ergebnisse werden als übertragbar auf die Instandsetzung bewertet.

⁶ Life Cycle Costing (dt.: Lebenszykluskostenrechnung).

⁷ Life Cycle Assessments (dt.: Lebenszyklusanalyse bzw. Ökobilanz).

⁸ Begründet in Kapitel 2.1.2.13.

jeden Objektes, auf die Ermittlung der spezifischen Lebensdauer, auf Basis entsprechender Methoden zur Bestimmung des Bauteilalters, gesetzt.

Grundsätzlich lassen sich Methoden zur Beschreibung des Alterungsprozesses von Bauteilen in stochastische und anwendungsorientierte Näherungsmethoden unterteilen. Stochastische Methoden versuchen, den Alterungsprozess eines spezifischen Bauteils auf Basis probabilistischer⁹ Ansätze möglichst exakt zu beschreiben. Anwendungsorientierte Näherungsmethoden hingegen bestimmen die spezifische Lebensdauer eines Bauteils auf der Grundlage einer statistischen Lebensdauer mit oder ohne Korrekturfaktoren. Im Bauwesen werden meist anwendungsorientierte Näherungsmethoden verwendet, da sich die hohen Kosten für die Anwendung stochastischer Methoden in der Regel nicht rechnen [7, 11].

Die Qualität der Ergebnisse einer jeden anwendungsorientierten Näherungsmethode richtet sich damit direkt nach der Qualität der verwendeten Lebensdauern der Bauteile.

Statistische Lebensdauern gibt es in Deutschland für Gebäude viele, eine Zusammenstellung von diversen publizierten Lebensdauern wurde von dem Bund Technischer Experten e.V. (Abkürzung: BTE) zuletzt im Jahr 2019 veröffentlicht [12]. Am Beispiel der Außenwand aus dem Werkstoff Beton kann man erkennen, dass die Angaben zu den Lebensdauern in den jeweiligen Veröffentlichungen teilweise stark divergieren. Die Angaben reichen hier von 80 Jahren bis zu 120 Jahren [8]. Bei einer Umfrage unter den Mitgliedern im Jahr 2008 zu Erfahrungswerten wurden Angaben zur Lebensdauer von Betonaußenwänden zwischen 73 und 120 Jahren gemacht (vgl. Anhang A 9). Die BTE Arbeitsgruppe spricht dabei in der aktuellsten Fassung aus dem Jahr 2019 eine Empfehlung von 90 Jahren aus [12] (vgl. Anhang A 11).

Dieses Problem der ungenauen Lebensdauer findet sich bei allen Bauteilen wieder, so sind in der Abbildung 2 die unterschiedlichen Lebensdauern eines Kunststofffensters aus verschiedenen Veröffentlichungen grafisch dargestellt.




Abbildung 2: Lebensdauerschätzungen aus der Literatur am Beispiel Kunststofffenster (Quelle: modifizierte Darstellung nach [7] S. 2)

⁹ Eintreten eines Sachverhaltes unter einer bestimmten Wahrscheinlichkeit (vgl. [10]).

Die in der Abbildung 2 dargestellten Werte beziehen sich auf durchschnittliche Qualitäten und Beanspruchungsklassen.¹⁰

Institutionen wie das Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) publizieren daher Intervalle der Lebensdauer, die sowohl Minimal- als auch Maximalwerte oder Mittelwerte dieser Intervalle enthalten.

Bei der Bearbeitung des Forschungsprojektes „Operationalisierung mittels künstlicher Intelligenz bei Gebäuden (OPKI)“ [19] konnten ähnlich große Spannbreiten bei der Untersuchung des Alterungsprozesses von Bauteilen beobachtet werden. Betonaußenwände wiesen trotz gleichen Baujahres und des gleichen Ausführungsstandards signifikante Unterschiede im Zustand des Bauelementes auf, der Abnutzungsvorrat der Elemente wurde also mit einem unterschiedlichen Alterungsverhalten abgebaut. Diese Auffälligkeit war umso deutlicher zu beobachten, je geringer die statistische durchschnittliche Lebensdauer dieser Elemente ist. Gründe hierfür können alle Faktoren sein, die sich direkt oder indirekt auf das Alterungsverhalten des Bauteils auswirken können. Neben des Ausführungsstandards gehören dazu auch die Art der Nutzung, die Qualität der Instandhaltung und die Umgebungsbedingungen [7].

Neben Ritter [7] stellten auch Bahr und Lennerts [11] in ihrem Forschungsbericht 2010 fest, dass eine fehlende bzw. nur marginale Berücksichtigung der Einflussfaktoren ein zentrales Problem bei vielen Näherungsmethoden darstellt.

Ritter [7] betrachtet deswegen die Faktorenmethode nach der ISO 15686 als grundsätzlich sehr sinnvoll, weil diese die spezifischen Randbedingungen mit der Hilfe von Einflussfaktoren rechnerisch berücksichtigt [11].

Trotzdem benennt er auch einige Schwächen der Methode und bezeichnet daher im Ganzen die Ergebnisse als unsicher und unvollständig [7]. Bahr und Lennerts versuchen die Faktorenmethode nach ISO 15686 durch Empfehlungen, restriktive Vorgaben und zusätzliche Differenzierungen der Einflussfaktoren zu verbessern [11]. Ritter kommentiert ein Jahr später den Ansatz von Bahr und Lennerts, dass dieser mit erheblichem Aufwand verbunden wäre und auch sehr spezifisches Fachwissen voraussetzen würde [7].

Methodische Ansätze, die das Problem mittels Künstlicher Intelligenz zu lösen versuchen, gibt es bis heute keine.

Der Begriff „Künstliche Intelligenz“ (Abkürzung: KI; engl.: artificial intelligence, Abkürzung: AI) ist in letzter Zeit sehr populär geworden, obwohl bereits in den 1940er Jahren erste Forschungen im Bereich Künstliche Intelligenz getätigt wurden. Den Anfang bildete dabei die sogenannte McCulloch-Pitts-Zelle, ein mathematisches Modell künstlicher Neuronen, welches die Forscher McCulloch und Pitts entwickelten [20]. Der Begriff der „Künstlichen Intelligenz“ wurde im Jahr 1955 durch den amerikanischen Informatiker John McCarthy (Dartmouth College) in einem Förderantrag geprägt [21].

¹⁰ Eine vertiefte Auseinandersetzung mit den Auswirkungen der Qualitäten und Beanspruchungsklassen auf die Lebensdauer von Bauteilen finden Sie in der Dissertation „Bestimmung der Herstellungskosten und Instandsetzungskosten sowie der Grauen Energie für die Gesamtnutzungsdauer unterschiedlicher Immobilientypen unter besonderer Berücksichtigung der Lebensdauer der Bauteile“ von Reiser [18].

Ab diesem Zeitpunkt wurde versucht die KI kommerziell zu nutzen, die Erfolge diesbezüglich waren aber sehr mäßig und endeten in dem sogenannten „KI-Winter“. Erst im Jahr 2000 mit dem großen Erfolg des Internets und der damit einhergehenden Digitalisierung erhielt das Thema KI eine Renaissance. Neue Technologien erforderten neue Methoden, um die großen Mengen an anfallenden Daten bearbeiten zu können. Maschinelles Lernen, ein Teilgebiet der „Künstlichen Intelligenz“ (vgl. Kapitel 2.3), war ein Ansatz, für den es plötzlich sehr viele neue Anwendungsfelder gab.

McKinsey prognostiziert, dass KI weltweit einen Umsatz von ca. 12 Billionen Euro bis zum Jahre 2030 generieren wird [22]. Das DIN und die DKE haben im Dezember 2022, gefördert durch das Bundesministerium für Wirtschaft und Klimaschutz, die zweite Auflage der Normungsroadmap „Künstliche Intelligenz“ veröffentlicht, um die Technologielandschaft in Deutschland zu strukturieren und die Anforderungen an das Thema „Künstliche Intelligenz“ zu definieren [23].

In den letzten acht Jahren hat sich die Leistungsfähigkeit der künstlichen Intelligenz stark verändert. Bis 2015 waren alle generativen KI-Systeme (vgl. Kapitel 2.3.2.8) der Leistung des menschlichen Gehirns unterlegen. Seit 2015 werden Modelle entwickelt, die in Benchmarktests (vgl. Abbildung 4) deutlich besser abschneiden als Menschen. Seit dem Jahr 2019 gilt dies für Handschrifterkennung, Leseverständnis, Spracherkennung, Sprachverstehen und Bildererkennung [24]. Diese Entwicklung ist in der Abbildung 4 illustriert, dabei wird, basierend auf den Daten von Klela, Bartolo et al. [24] aus dem Jahr 2021, dargestellt, in welchen Data-sets von AI-Modellen welche Performance erreicht wird bzw. wurde. Die Nulllinie entspricht dabei der menschlichen Leistung bei den jeweiligen Datasets.

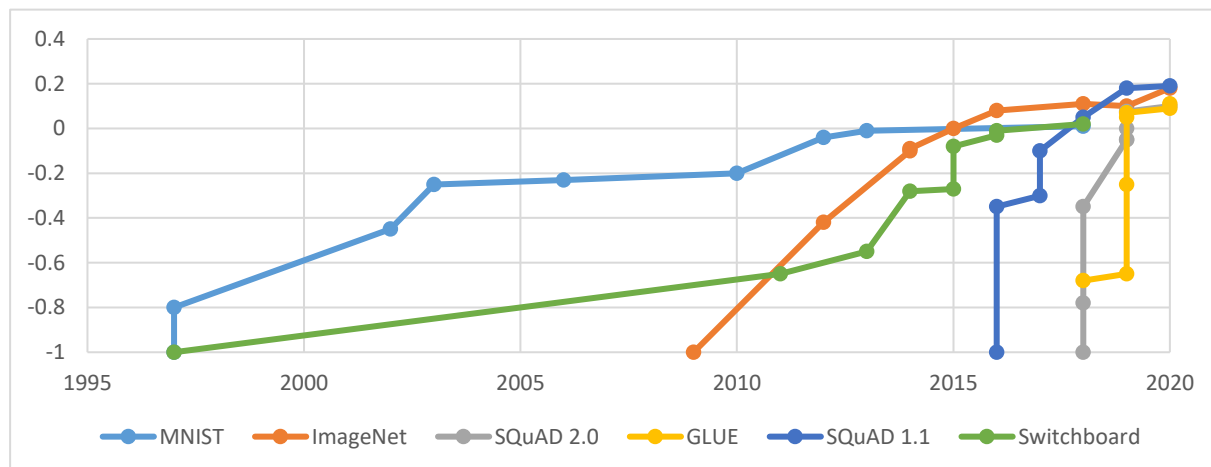


Abbildung 3: Benchmark-Sättigung im Laufe der Zeit für beliebige Benchmark-Datasets, normalisiert mit einer Ausgangsleistung von minus eins und einer menschlichen Leistung von null (Quelle: eigene Darstellung nach [24])¹¹

¹¹ **GLUE**: Dataset für das Sprachverständnis (NLP); **ImageNet**: Dataset für die Bildererkennung; **MNIST**: Dataset für die Handschrifterkennung (Modified National Institute of Standards and Technology database); **SQuAD 1.1**: Dataset für das Leseverständnis (Stanford Question Answering Dataset); **SQuAD 2.0**: Dataset für das Leseverständnis (Stanford Question Answering Dataset); **Switchboard**: Dataset für die Spracherkennung.

Diese signifikanten Fortschritte in der KI-Technologie führen zu der Motivation innerhalb dieser Arbeit, die Einflussfaktoren auf das Alterungsverhalten von Bauelementen von Bauwerken im Hochbau durch den Einsatz von Künstliche Intelligenz mit in die Ermittlung der Lebensdauern einzubeziehen und damit die Lebensdauern, in Abhängigkeit dieser Einflussfaktoren, zu präzisieren. Die Anwendung der geläufigen Methoden wäre damit hinfällig.

Solche individuellen Lebensdauern verbessern nicht nur, im Vergleich zu den bisher verwendeten Referenzlebensdauern und Ansätzen zur Berechnung, die Effizienz der Instandhaltung, sondern auch die Qualität der daraus resultierenden Lebenszykluskostenberechnungen.

1.2 Zielsetzung

Ziel dieser Arbeit ist es, exemplarisch an der Außenhülle von Gebäuden eine KI-basierte Methode zu entwickeln, mit der genauere Angaben zu Lebensdauern beziehungsweise dem Alterungsprozess von Bauteilen getätigt werden können. Die Ermittlung der Kosten für Instandhaltungsmaßnahmen, welche sich in der Regel aus einem Verschnitt von Erfahrungswerten und stochastischen Lebensdauerdaten zusammensetzt, kann mit genaueren Lebensdauern dadurch transitiv¹² verbessert werden.

Insbesondere für Kommunen mit einem umfangreichen Gebäudebestand ist es äußerst schwierig, den Zustand der einzelnen Bauteile eines Gebäudes ohne aufwändige und kostenintensive regelmäßige Inspektionen zu erfassen.

In Deutschland wird zur Lebensdauerermittlung die Faktorenmethode nach DIN ISO 15686 angewendet, die durch die Berücksichtigung vielfältiger Einflussfaktoren eine präzisere Bestimmung der Lebensdauer ermöglichen soll. Die Berechnung der Lebensdauer nach ISO 15686 mit der Faktorenmethode erweist sich in der Praxis als sehr anspruchsvoll, da die ISO 15686 in vielerlei Hinsicht Interpretationsspielraum und offene Fragen lässt. Dies führt zu einer Vielzahl von Variablen bei der Bestimmung der Lebensdauer, die zu potenziell ungenauen Ergebnissen führen können.

Bereits Ritter [7] sowie Bahr und Lennerts [11] haben sich wissenschaftlich mit der Weiterentwicklung der Faktorenmethode beschäftigt, um deren Verbesserungsmöglichkeiten zu untersuchen und Optimierungsmöglichkeiten zu bieten.

Die Schwierigkeiten, die sich bei der Berechnung der Lebensdauer nach ISO 15686 durch Interpretationsspielräume und offene Fragen ergeben, sollen durch die Anwendung dieser KI-basierten Methode überwunden werden. Der hier vorgestellte Ansatz wird als grundlegend verschieden von der bisherigen Faktorenmethode betrachtet und zielt darauf ab, genauere Informationen über Lebensdauern und Alterungsprozesse zu liefern. Dadurch sollen individualisierte Lebensdauerprognosen mit höherer Genauigkeit ermöglicht werden, als es mit der Faktorenmethode möglich ist.

¹² Für alle $a, b, c \in M$ gilt: wenn $a, b \in R$ und $b, c \in R$, dann $a, c \in R$. Wenn KI zu präziseren Lebensdauern führt, präzisere Lebensdauern zu präziseren Ermittlungen der Kosten für Instandhaltungsmaßnahmen führt, dann führt somit KI indirekt zu einer präziseren Ermittlung der Kosten für Instandhaltungsmaßnahmen.

1.3 Vorgehensweise

Diese Arbeit beginnt mit einer Einleitung und einer Darstellung der Problemstellung, der Ziele und der Vorgehensweise, um eine solide Basis für die nachfolgenden Untersuchungen zu schaffen.

Zum Erreichen der Zielsetzung wird in dieser Arbeit folgendermaßen vorgegangen:

Nach einer einleitenden Darstellung der Problemstellung, der Zielsetzung und des methodischen Vorgehens folgt das Kapitel "Grundlagen". Hier werden dem Leser in kompakter Form Begriffsdefinitionen und der aktuelle Stand der Forschung in den Bereichen Instandhaltung, Lebensdaueranalyse von Bauteilen und künstliche Intelligenz erläutert. Eine Auflistung der für diese Arbeit relevanten Normen schließt dieses Grundlagenkapitel ab.

Unmittelbar darauf aufbauend beginnt der Hauptteil der Arbeit mit dem Kapitel "Analyse verschiedener Methoden zur Lebensdauerbestimmung". An dieser Stelle werden alle gängigen Lebensdauerermittlungsverfahren nach dem aktuellen Stand der Forschung ausführlich dargestellt.

Nach der Erläuterung der Lebensdauerermittlungsverfahren folgt das Kapitel "*Bauteile im Bauwesen nach DIN 276*", in dem die Kostenstruktur des Hochbaus nach DIN 276 erläutert wird. Darüber hinaus wird die erweiterte Kostengruppenstruktur aus den Forschungsvorhaben FM^{EM} [25] und FM^{EM} 2 [26] vorgestellt.

Kapitel fünfte befasst sich eingehend mit den materiellen und immateriellen Einflussfaktoren, die die Lebensdauer von Bauteilen bestimmen. In diesem Kapitel wird die Entscheidung, den Schwerpunkt dieser Arbeit auf die materiellen Einflüsse aus der äußeren Umgebung zu legen, ausführlich erläutert.

Das sechste Kapitel ist der genauen Auswahl der für den Kontext dieser Forschungsarbeit relevanten Bauteile gewidmet. Im Rahmen dieses Kapitels wird eine ausführliche Begründung für den Prozess der Bauteilauswahl gegeben und methodisch untermauert, warum ausschließlich Bauteile der äußeren Gebäudehülle für die vorliegende Untersuchung betrachtet werden.

In Kapitel sieben werden die Standorte vorgestellt, von denen die standortspezifischen Inspektionsdaten stammen. Für jeden Standort werden die relevanten Einflussfaktoren der äußeren Umgebung beleuchtet. Das Kapitel schließt mit einer Zusammenfassung.

In Kapitel acht "Datengrundlage" wird ausführlich auf die Herkunft der Daten eingegangen, die für das Training des neuronalen Modells verwendet wurden. Im Detail wird beschrieben, wie diese Daten entstanden, die umfangreiche Datenaufbereitung sowie die Generierung der synthetischen Daten erfolgte. Das letzte Kapitel dieses Abschnitts widmet sich schließlich der grafischen Korrelationsanalyse der vorliegenden Datenbasis.

Das neunte Kapitel ist der Modellentwicklung gewidmet und gliedert sich in drei Unterkapitel. Im ersten Unterkapitel „Theoretisches Modell“ wird die Struktur und die einzelnen Komponenten des theoretischen Modells beschrieben. Dieses Modell bildet die Grundlage für die folgende Modellierung und definiert die einzelnen Komponenten des theoretischen Ansatzes.

Im zweiten Unterkapitel „Neuronales Modell“ wird die konkrete Modellierung des neuronalen Modells basierend auf dem theoretischen Modell dargestellt. Im dritten Unterkapitel „Prototyp“ erfolgt die praktische Umsetzung des neuronalen Modells. Dabei werden die

Prototypenerstellung, die technische Realisierung und die Anwendung des Modells beschrieben. Der Fokus liegt auf der Validierung des Modells durch Tests und Experimente sowie der Diskussion von Herausforderungen und Optimierungen.

Das zehnte Kapitel enthält eine kritische Auseinandersetzung mit dem verwendeten Datensatz sowie eine detaillierte Analyse der Ausgabedaten des neuronalen Modells. Dabei werden verschiedene Szenarien, mit unterschiedlichen Kombinationen von äußeren Umwelteinflüssen definiert und dem neuronalen Modell übergeben. Mit den ermittelten Abnutzungsvorräten wird für alle betrachteten Bauteile der Verlauf der Abnahme des Abnutzungsvorrates über die gesamte Lebensdauer als Kurve grafisch dargestellt.

Die Arbeit schließt mit einer kritischen Analyse der Zielerreichung im elften Kapitel sowie einem Ausblick im zwölften Kapitel. Im elften Kapitel erfolgt eine Bewertung des Erreichens der Zielsetzung, wobei auch auf methodische Schwächen und Limitationen eingegangen wird. Das zwölfte Kapitel bietet einen Ausblick auf zukünftige Forschung und mögliche Weiterentwicklungen, um die gewonnenen Erkenntnisse weiter zu vertiefen und anzuwenden.

Um punktlose Abschnittsenden zu vermeiden, sollten Quellenangaben, die sich auf einen Abschnitt beziehen, vor dem Punkt stehen. Allerdings kann dadurch unklar werden, ob sich die Quellenangabe auf den gesamten Abschnitt oder nur auf den letzten Satz bezieht. Diese Ungenauigkeit wird in dieser Arbeit aus ästhetischen Gründen toleriert [27].

Für diese Arbeit wird der naturwissenschaftliche Zitationsstil Springer Vancouver (Numbers) mit eckigen Klammern verwendet. Dieser Stil ermöglicht eine klare Identifikation von Quellen und erleichtert die Nachvollziehbarkeit wissenschaftlicher Verweise. Da dieser Zitationsstil keine Seitenangaben berücksichtigt, wurden diese - sofern erforderlich - in runden Klammern unmittelbar nach der Quellenangabe ergänzt.

2 Grundlagen

2.1 Instandhaltung von Gebäuden

2.1.1 Einführung

Fachübergreifend kann man Instandhaltung als die Gesamtheit aller Maßnahmen definieren, die den Soll-Zustand von Maschinen, Gebäuden, Anlagen oder anderen Objekten bewahren oder steigern, sowie alle Maßnahmen, mit denen der Ist-Zustand erfasst werden kann.

Das übergeordnete Ziel der Instandhaltung ist die Maximierung der Lebensdauer.

Eine gute Instandhaltung kann dazu beitragen, Störungen und Folgekosten zu vermeiden. Wirtschaftlich betrachtet werden die Kosten der Instandhaltung den Betriebskosten bzw. Nutzungskosten zugeordnet und wirken sich daher auf Rentabilitätsberechnungen von Maschinen oder Immobilien aus. Gerade in den letzten Jahren hat sich die Bedeutung der Instandhaltung im Kontext von Nachhaltigkeit und dem effizienten Einsatz von Ressourcen verstärkt.

Im Bereich der Instandhaltung werden in Deutschland viele Begriffe, auch in der beruflichen Domäne des Bauwesens, falsch verwendet oder durch Synonyme der Umgangssprache ersetzt.

Für ein einheitliches Verständnis werden im ersten Unterkapitel die wichtigsten Fachbegriffe der Instandhaltung kurz definiert und erläutert. Im folgenden Kapitel wird abgegrenzt, welche Teile der Instandhaltung für diese Arbeit relevant sind.

2.1.2 Begriffserklärungen

2.1.2.1 Abnutzung

Die Abnutzung beschreibt den Abbau des Abnutzungsvorrates durch chemische und/oder durch physikalische Vorgänge [4].

2.1.2.2 Abnutzungsgrenze

Eine Festlegung über den kleinstmöglichen Abnutzungsvorrat wird als Abnutzungsgrenze bezeichnet [4].

2.1.2.3 Abnutzungsprognose

Die Abnutzungsprognose ist eine Vorhersage über das Abnutzungsverhalten eines Objekts, ermittelt über den Abnutzungsmechanismen aus den bekannten sowie angenommenen Belastungen der zukünftigen Bedarfsforderungen, basierend auf dem aktuellen Zustand des Objekts [4].

2.1.2.4 Abnutzungsvorrat

In der DIN 31051 wird der Abnutzungsvorrat als „Vorrat der möglichen Funktionserfüllungen unter festgelegten Bedingungen, der eines Objekts aufgrund der Herstellung, Instandsetzung oder Verbesserung innewohnt“ [4] beschrieben. Neben dieser Erläuterung findet man dort auch eine grafische Darstellung (vgl. Abbildung 4).

Zu Abbildung 4: Die vertikale Achse (Y) steht für den Abnutzungsvorrat, die horizontale Achse (X) für die Zeit. Position 1 ist der Ausgangszustand nach der Herstellung (100 % Abnutzungsvorrat), die Linie 3 repräsentiert die Abnutzungsgrenze und Position 4 den Ausfallzeitpunkt des Bauteiles. Die Position 2 stellt den Zustand nach einer Instandsetzung oder Schwachstellenbeseitigung dar.




Abbildung 4: Grafische Darstellung des Abnutzungsvorrates in der DIN 31051 (Quelle: [4] S. 8)

2.1.2.5 Ausfall

In der DIN 31051 wird ein Ausfall als der Verlust der Fähigkeit eines Objekts definiert, eine geforderte Funktion zu erfüllen. Dabei wird zwischen dem Ereignis „Ausfall“ und dem Zustand „Fehler“ differenziert. [4].

2.1.2.6 Gebäudemanagement

Die Leistungen des Gebäudemanagements (kurz: GM) sind in der DIN 32736 beschrieben. Unter dem Dach des Gebäudemanagements werden alle dazugehörigen Leistungen in die drei Leistungsbereiche des technischen Gebäudemanagements (kurz: TGM), des infrastrukturellen Gebäudemanagements (kurz: IGM) und des kaufmännischen Gebäudemanagements (kurz: KGM) untergliedert (vgl. Abbildung 5) [28].

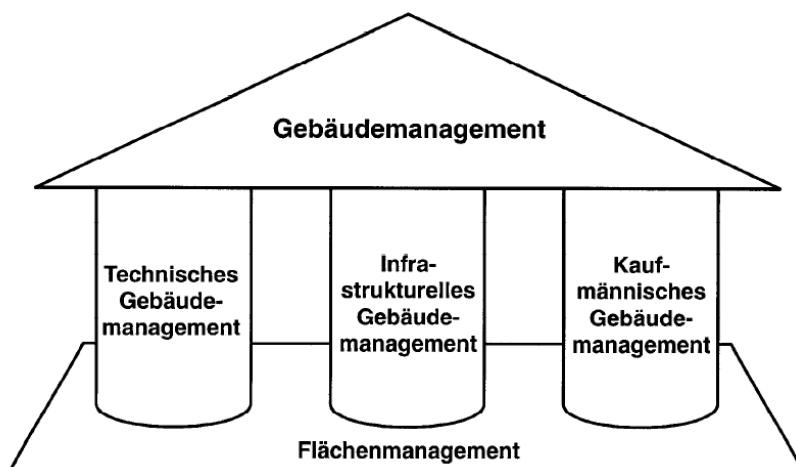


Abbildung 5: Leistungsbereiche des Gebäudemanagements nach DIN 32736 (Quelle: [28] S. 2)

Technisches Gebäudemanagement (TGM)

„Leistungen, die zum Betreiben und Bewirtschaften der baulichen und technischen Anlagen eines Gebäudes erforderlich sind“ [28].

- „Betreiben,
- Dokumentieren,
- Energiemanagement,
- Informationsmanagement,
- Modernisieren,
- Sanieren,
- Umbauen,
- Verfolgen der technischen Gewährleistung.“ [28] (S. 2)

Instandhaltung (Warten, Inspizieren, Instandsetzen) nach DIN 31051 wird in der DIN 32736 dem Betreiben des TGM zugeordnet. Die in der DIN 31051 der Instandhaltung zugeordnete „Verbesserung“ wird in der DIN 32736 als eigenständiger Leistungsbereich geführt [28]. Nähere Erläuterungen dazu befinden sich in dem Unterkapitel Instandhaltung.

Infrastrukturelles Gebäudemanagement (IGM)

„geschäftsunterstützende(n) Dienstleistungen, welche die Nutzung von Gebäuden verbessern“ [28].

- „Verpflegungsdienste,
- DV-Dienstleistungen,
- Gärtnerdienste,
- Hausmeisterdienste,
- Interne Postdienste,
- Kopier- und Druckereidienste,
- Parkraumbetreiberdienste,
- Reinigungs- und Pflegedienste,
- Sicherheitsdienste,

- Umzugsdienste,
- Waren- und Logistikdienste,
- Winterdienste,
- Zentrale Telekommunikationsdienste,
- Entsorgen,
- Versorgen.“ [28] (S. 4)

Kaufmännisches Gebäudemanagement (KGM)

„*kaufmännische(n) Leistungen aus den Bereichen TGM, IGM unter Beachtung der Immobilienökonomie*“ [28].

- „Beschaffungsmanagement,
- Kostenplanung und -kontrolle,
- Objektbuchhaltung,
- Vertragsmanagement.“ [28] (S. 7)

2.1.2.7 Instandhaltung

Der Begriff der Instandhaltung wird in der DIN EN 13306:2018-02 und der DIN 31051:2019-06 folgendermaßen definiert: „Kombination aller technischen und administrativen Maßnahmen sowie Maßnahmen des Managements während des Lebenszyklus eines Objekts, die dem Erhalt oder der Wiederherstellung seines funktionsfähigen Zustands dient, sodass es die geforderte Funktion erfüllen kann.“ [4, 5] In der DIN EN 13306:2018-02 wird die Instandhaltung nicht nach Maßnahmen strukturiert, sondern lediglich in verschiedene Instandhaltungsarten unterteilt. Die übergeordneten Instandhaltungsarten (1. Ebene) sind dabei die präventive Instandhaltung und die korrektive Instandhaltung sowie die Verbesserung [5]:

- I. Präventive Instandhaltung: Vorbeugende Instandsetzung (engl.: preventive maintenance).
- II. Korrektive Instandhaltung: Instandsetzung nach Störungen (engl.: corrective maintenance).
- III. Verbesserung (engl.: improvement).

Eine grafische Darstellung der ersten Ebene ist in der Abbildung 6.

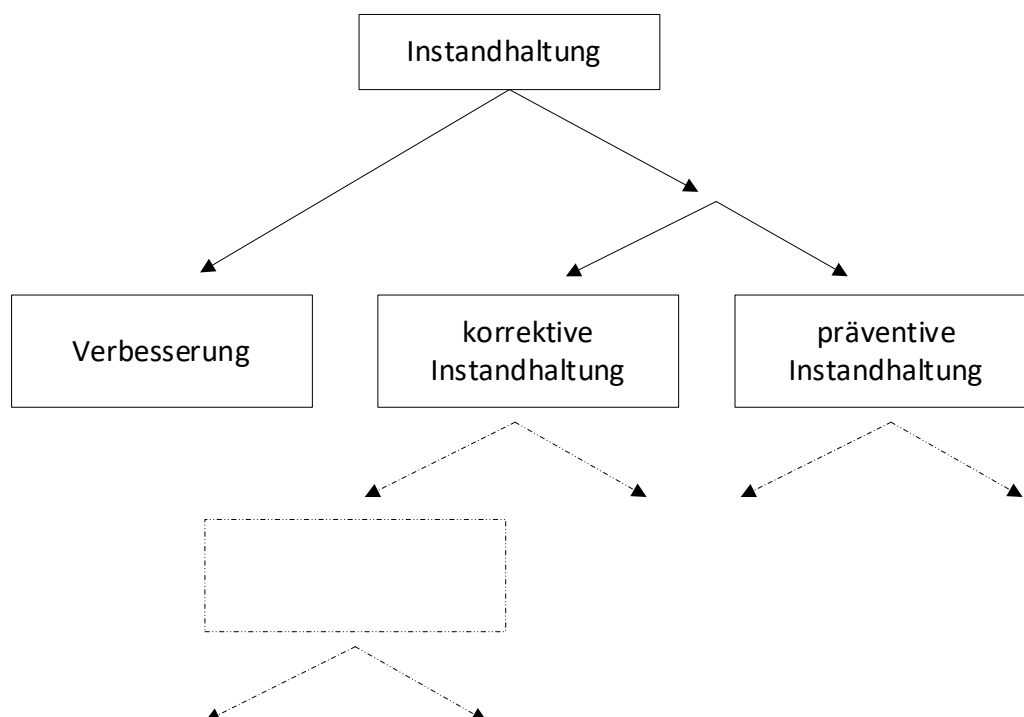


Abbildung 6: Übersicht der ersten Ebene der Instandhaltungsarten nach DIN EN 13306:2018-02 (Quelle: eigene Darstellung nach [5])

Im Gegensatz dazu unterteilt die DIN 31051:2019-06 die Instandhaltung nicht nach Arten, sondern nach Grundmaßnahmen [4] (vgl. Abbildung 5):

- I. Wartung,
- II. Inspektion,
- III. Instandsetzung,
- IV. (Verbesserung der Funktionssicherheit/Verbesserung).




Abbildung 7: Unterteilung der Instandhaltung nach DIN 31051:2019-06 (Quelle: [4] S. 12)

Neben der DIN EN 13306:2018-02 und der DIN 31051:2019-06 beschäftigt sich auch die DIN 32736:2000-08 mit der Thematik Instandhaltung.

Der Begriff Instandhaltung (Warten, Inspizieren, Instandsetzen) nach DIN 32736:2000-08 gliedert den Begriff „Verbesserung“ aus der Instandhaltung aus. In der DIN 32736:2000-08 ist die „Verbesserung“ nicht als eigenes Leistungsbild zu finden, sondern ein Bestandteil des Leistungsbildes „Modernisieren“ [4]. Modernisieren beinhaltet per Definition die Verbesserung, die

Begriffe sind aber grundsätzlich nicht als Synonyme zu verwenden. Eine Differenzierung der Termini enthalten die entsprechenden Kapitel zu Modernisierung und Verbesserung.

Begründen lassen sich diese Differenzen in den Definitionen der Instandhaltung in den verschiedenen Normen dadurch, dass die DIN 31051 ursprünglich aus dem Bereich des Maschinenbaus kommt und die DIN 32736 explizit für das Gebäudemanagement entwickelt wurde. Deswegen wird bei der Orientierung bei der Begrifflichkeit die DIN 32736 empfohlen [29, 30].

Außerdem ist eine harmonisierte Festlegung auf die europäische Norm DIN EN 13306 aktuell noch nicht abgeschlossen.

Im Rahmen dieser Arbeit wird der Begriff „Instandhaltung“ gemäß den Grundmaßnahmen der DIN 31051:2019-06 [4] verwendet, eine grafische Darstellung findet sich in der Abbildung 7.

2.1.2.8 Instandhaltungsstrategie

Unter Instandhaltungsstrategie versteht man die Vorgehensweise zur Erreichung der definierten Instandhaltungsziele [5].

In der Literatur beschreibt eine Vielzahl von Autoren unterschiedliche Strategien für das Instandhaltungsmanagement. Gewöhnlich bauen aktuelle Strategien auf den drei Grundstrategien von Bateman [31] aus dem Jahr 1995 auf:

- I. Reaktive Instandhaltungsstrategie: Instandhaltungsmaßnahmen werden erst dann durchgeführt, wenn ein Schaden vorliegt.
- II. Präventive Instandhaltungsstrategie: Instandhaltungsmaßnahmen werden in regelmäßigen Zeitabständen durchgeführt.
- III. Prädiktive Instandhaltungsstrategie: Instandhaltungsmaßnahmen werden geplant durchgeführt, die Planung leitet sich von dem gegenwärtigen Ist-Zustand und der Abnutzungsprognose ab.

Die Strategien II und III besitzen einen proaktiven Charakter.

King [32] unterteilte 2019 die Strategien in die „ausfallbedingte Instandhaltungsstrategie“ und die „vorbeugende Instandhaltungsstrategie“:

- a. Ausfallbedingte Instandhaltungsstrategie
- b. Vorbeugende Instandhaltungsstrategie
 - i. Präventive Instandhaltungsstrategie
 - ii. Inspektionsstrategie

Manche Autoren ergänzen dieses Schema um die sogenannte aggressive Instandhaltungsstrategie, diese geht über die Bestrebungen eines reinen „Instandhaltens“ hinaus und hat das übergreifende Ziel einer „Null-Verschwendung“, eine Maximierung der Gesamteffektivität von Anlagen bei minimalem Ressourceneinsatz [33–35]. Auf eine weitere Erläuterung dieser Strategie wird an dieser Stelle verzichtet, weil diese Instandhaltungsstrategie sich ausschließlich auf die Instandhaltung von Industrieanlagen bezieht.

2.1.2.9 Instandhaltungsziele

Als Instandhaltungsziele bezeichnet man die zugewiesenen und akzeptierten Ziele für die Instandhaltungstätigkeiten [5].

2.1.2.10 Instandsetzung

Eine physische Maßnahme, die zur Wiederherstellung der Funktion eines fehlerhaften Objekts ausgeführt wird, bezeichnet man als Instandsetzung [4, 5].

Die DIN 13306 beinhaltet an der Stelle der Begriffsdefinition folgende zwei Anmerkungen: „Die Instandsetzung umfasst auch Fehlerortung und Funktionsprüfung“ [5] (S. 44) sowie „Fehlerkorrektur hat dieselbe Bedeutung wie Instandsetzung“ [5] (S.44).

2.1.2.11 Inspektion

Die DIN 31051 beschreibt die Inspektion als „Prüfung auf Konformität der maßgeblichen Merkmale eines Objekts (3.2.1), durch Messung, Beobachtung oder Funktionsprüfung“ [4]. Inspektionen werden von einer befähigten Person, einem Inspekteur, durchgeführt.

Ziel der Inspektion ist die Feststellung und Beurteilung des Ist-Zustandes einer Betrachtungseinheit (vgl. Abbildung 8) sowie dessen Dokumentation. Dabei sollen auch die Ursachen einer potenziell unüblichen Abnutzung untersucht werden [36].




Abbildung 8: Exemplarische Darstellung einer Inspektion (Quelle: modifizierte Darstellung nach [37])

2.1.2.12 Kostengruppen

Die DIN 276 definiert Kostengruppen als „Zusammenfassung einzelner, nach den Kriterien der Planung zusammengehörender Kosten“ [38] (S. 5). Aufgrund der entscheidenden Bedeutung der Kostengruppen nach DIN 276 für die vorliegende Forschungsarbeit wird der DIN 276 ein eigenes Kapitel gewidmet (vgl. Kapitel 4).

2.1.2.13 Lebensdauer

Der Begriff der Lebensdauer in der Instandhaltung differenziert sich in die [8]:

- I. Technische Lebensdauer
- II. Wirtschaftliche Lebensdauer

Die technische Lebensdauer muss mit der wirtschaftlichen Lebensdauern von Bauelementen nicht übereinstimmen, meist liegen signifikante Unterschiede vor [8].

In Bezug auf Bauteile handelt es sich bei der technischen Lebensdauer um die Zeitspanne zwischen dem Einbau und dem Ausfall, dem Erreichen der Abnutzungsgrenze.

Das Ende der technischen Lebensdauer eines Bauteils ist erreicht, wenn es seine „Funktion nicht mehr erfüllen kann, Instandhaltungsmaßnahmen technisch nicht mehr möglich sind und das Bauteil ausgetauscht werden muss.“ [11] (S. 16).

Bei der wirtschaftlichen Lebensdauer handelt es sich hingegen um den Zeitraum, während dessen aus ökonomischer Sicht eine Nutzung sinnvoll ist.

Das Ende der wirtschaftlichen Lebensdauer ist erreicht, wenn die Kosten für die Nutzung die Erträge übersteigen, also keine Rentabilität mehr gegeben ist [7, 11].

Damit unterliegt die wirtschaftliche Lebensdauer wirtschaftlichen und gesellschaftlichen Einflüssen. Die wirtschaftliche Lebensdauer wäre beispielsweise erreicht, wenn sich die Kosten für eine Instandsetzungsmaßnahme für das Objekt im Gesamten nicht mehr rentieren. Die wirtschaftliche Lebensdauer ist in der Regel kürzer als die technische Lebensdauer [11].

In der Literatur wird manchmal der betriebswirtschaftliche Begriff Nutzungsdauer synonym mit der Lebensdauer verwendet [39].

In der Betriebswirtschaftslehre wird die Nutzungsdauer als die Zeitspanne zwischen der Investition und der Desinvestition eines Wirtschaftsgutes definiert [40]. Wobei zwischen der technischen, der wirtschaftlichen und rechtlichen Nutzungsdauer differenziert wird [41].

Aus diesem Grund entspricht aus ökonomischer Sicht die wirtschaftliche Nutzungsdauer der wirtschaftlichen Lebensdauer bzw. die technische Nutzungsdauer der technischen Lebensdauer.

In diesem Zusammenhang existiert der rechtliche Begriff der betriebsgewöhnlichen Nutzungsdauer nach §7 Abs. 1 EStG¹³. Die betriebsgewöhnlichen Nutzungsdauern werden durch das Bundesministerium der Finanzen veröffentlicht (AfA¹⁴-Tabellen). Auf Basis dieser Nutzungsdauern kann steuerrechtlich die Wertminderung von Anlagenvermögen ermittelt werden.

2.1.2.14 Lebenszyklus

Der Lebenszyklus eines Gebäudes ist das Zeitintervall zwischen der Konzipierung und dem Abriss des Gebäudes [42].

¹³ Einkommensteuergesetz.

¹⁴ Absetzung für Abnutzung.

2.1.2.15 Lebenszykluskosten

Die Lebenszykluskosten (kurz: LZK) eines Gebäudes, in Englisch Life-Cycle-Costs (kurz: LCC), beschreiben die kumulierten Kosten eines Gebäudes über dessen gesamten Lebenszyklus [42].

2.1.2.16 Lebenszyklusphasen

Die Lebenszyklusphasen von Gebäuden werden im Detail durch die Lebenswegmodule der DIN EN 15804 beschrieben [43]. In der Regel wird der Lebenszyklus eines Gebäudes aber vereinfacht in die übergeordneten folgenden Phasen unterteilt [44, 45]:

- Planungsphase:
 - Projektentwicklung,
 - Planung.
- Bauphase:
 - Errichtung,
 - Inbetriebnahme.
- Nutzungsphase:
 - Instandhalten,
 - Betreiben,
 - Bewirtschaften,
 - Nutzen.
- Modernisierungsphase:
 - Umbau,
 - Instandsetzung,
 - Modernisierung.
- Nutzungsphase (nach Modernisierung):
 - Instandhalten,
 - Betreiben,
 - Bewirtschaften,
 - Nutzen.
- Rückbauphase:
 - Rückbauplan,
 - Rückbau,
 - Verwertung und Entsorgung.

2.1.2.17 Lebenszyklus von Gebäuden

Die DIN 13306 definiert den Lebenszyklus eines Gebäudes als eine Anzahl von Phasen, die ein Objekt durchläuft, von der Phase der Konzeption bis zur Phase der Entsorgung [5].

2.1.2.18 Modernisierung

Die DIN 13306 definiert Modernisierung als Änderung oder Verbesserung eines Objekts [5], grafisch illustriert in der Abbildung 9 [5]. In der DIN 32736 wird sie als „Leistungen zur Verbesserung des Istzustandes“ [28] (S. 3) bezeichnet.




Abbildung 9: Modernisierung als Vereinigungsmenge der Änderung und Verbesserung (Quelle: eigene Darstellung nach [5])

Ziel der Modernisierung ist dabei, unter der Berücksichtigung technologischer Fortschritte, neue oder geänderte Anforderungen zu erfüllen und die Wirtschaftlichkeit zu erhöhen [5, 28].

2.1.2.19 Nutzungskosten

Nach der DIN 18960 werden die Nutzungskosten im Hochbau als „alle in baulichen Anlagen und deren Grundstücken entstehenden regelmäßig wiederkehrenden Kosten, beginnend mit der Inbetriebnahme (Nutzungsdauer)“ [3] (S. 4) bezeichnet.

2.1.2.20 Reparatur

In Online-Quellen wird häufig aufgeführt, dass die Reparatur nach DIN 31051 Bestandteil der Instandhaltung ist, so wird es sogar auf der deutschen Wikipedia-Seite aufgegriffen [46], tatsächlich ist der Begriff in der DIN 31051 aber nicht definiert.

Auch Aussagen, dass Reparatur gleichbedeutend mit Instandsetzung ist, finden sich in der DIN 31051 nicht.

Die einzige Norm, die den Begriff Reparatur definiert, ist die DIN EN ISO 9000:2015-11 „Qualitätsmanagementsysteme - Grundlagen und Begriffe“ [47]: „Maßnahme an einem nichtkonformen (3.6.9) Produkt (3.7.6) oder einer nichtkonformen Dienstleistung (3.7.7), um diese(s) für den beabsichtigten Gebrauch annehmbar zu machen“ [47] (S. 58).

Relevant ist die zweite Anmerkung der Norm: „Reparatur schließt Abhilfemaßnahmen ein, die der Rückführung eines/einer früher fehlerfreien Produkts oder Dienstleistung in einen gebrauchsfähigen Zustand dienen, zum Beispiel als Teil der Instandhaltung.“ [47] (S. 59).

Daraus folgt, dass nach der Definition in DIN EN ISO 9000:2015-11 [47] die Reparatur die Instandsetzung einschließt. Das bedeutet, dass die Instandsetzung eine spezifische Form der Reparatur ist, aber nicht mit dem Begriff Reparatur gleichbedeutend ist.

2.1.2.21 Sanierung

Die Sanierung ist in der Regel umfassender als eine Instandsetzung. Ziel ist dabei eine Wiederherstellung der Standsicherheit und eines gebrauchstauglichen und zweckbestimmten nutzbaren Zustands [48]. Die DIN 32736 definiert den Begriff der Sanierung folgendermaßen: „Leistungen zur Wiederherstellung des Sollzustandes von baulichen und technischen Anlagen, die nicht mehr den technischen, wirtschaftlichen und/oder ökologischen sowie gesetzlichen Anforderungen entsprechen“ [28] (S. 3).

Betrachtet man die Kosten für die Sanierung und die Instandsetzung bei einer Lebenszykluskostenberechnung, lassen sich die beiden Begriffe insofern differenzieren, dass Instandsetzungskosten jährlich anfallende Kosten sind und Sanierungskosten periodisch einzubeziehen sind [49].

2.1.2.22 Verbesserung

Die DIN 31051:2019-06 und die DIN 13306:2018-02 definieren die Verbesserung als „Kombination aller technischen und administrativen Maßnahmen sowie Maßnahmen des Managements zur Steigerung der immanenten Zuverlässigkeit und/oder Instandhaltbarkeit und/oder Sicherheit eines Objekts, ohne seine ursprüngliche Funktion zu ändern“ [4, 5] (S. 6, S. 36).

Die Verbesserung wird nach DIN 13306 der Überkategorie Modernisierung zugeordnet (vgl. Kapitel 2.1.2.18). Eine Verwendung als Synonym ist daher falsch.

Die Verbesserung ist in der Abbildung 4 (Position 2) illustriert.

2.1.2.23 Wartung

Der Begriff Wartung umfasst alle Maßnahmen, die zu der Verzögerung des Abbaus des vorhandenen Abnutzungsvorrates beitragen [4].

Eine grafische Darstellung kann der Abbildung 10 entnommen werden.




Abbildung 10: Grafische Darstellung der Wartung (Quelle: modifizierte Darstellung nach [37])

Wartungsarbeiten können u.a. diese Maßnahmen enthalten:

- Auswechseln von Batterien (z.B. Feuermelder),
- Füllstandprüfungen,
- Funktionalitätsprüfungen,
- Reinigungsarbeiten,
- usw.

Wartungen werden in zeitlich regelmäßigen Abständen durchgeführt und in einem Wartungsplan bzw. -protokoll dokumentiert.

2.1.3 Abgrenzung dieser Arbeit

Bei der Betrachtung des Instandhaltungsprozesses wird auf die Grundmaßnahmen der DIN 31051:2019-06 [4] zurückgegriffen. Der Fokus liegt dabei ausschließlich auf der Maßnahme Inspektion (vgl. 3.1.3 in der Abbildung 11) als Element der Instandhaltung.




Abbildung 11: Unterteilung der Instandhaltung nach DIN 31051 (Quelle: modifizierte Darstellung nach [4] S. 12)

Begründet wird die Vernachlässigung der Wartung (vgl. 3.1.2 in der Abbildung 11), Instandsetzung (vgl. 3.1.4 in der Abbildung 11) und Verbesserung (vgl. 3.1.5 in der Abbildung 11) damit, dass das Ziel der Arbeit ist, Lebensdauerprognosen zu optimieren. Diese sind einzig von der Qualität der Maßnahme Inspektion abhängig.

Der Prozess der Inspektion ist in keiner Norm weiter untergliedert, er wird lediglich als „Prüfung auf Konformität der maßgeblichen Merkmale eines Objekts (3.2.1) durch Messung, Beobachtung oder Funktionsprüfung“ in der DIN 31051:2019-06 definiert [4].

Deswegen wird für diese Arbeit festgelegt, dass der Ablauf der Inspektion, für die in dieser Arbeit zu untersuchenden Gebäude folgendermaßen aussieht (vgl. Abbildung 12).




Abbildung 12: BPMN 2.0 Ablaufdiagramm der Inspektion für Gebäude in dieser Arbeit (Quelle: eigene Darstellung)

Eine größere Darstellung befindet sich im Anhang A 7.

Der Inspekteur identifiziert im ersten Schritt die Teilmenge der Bauelemente, die im Gebäude vorhanden sind. Die Gesamtmenge aller Bauelemente repräsentiert dabei die erweiterte Kostengruppenstruktur der DIN 276. Die Kostengruppenstruktur der DIN 276 sowie deren Erweiterung werden im Kapitel 3.6 erläutert. Im nächsten Schritt inspiziert er das erste Bauelement dieser Liste und vermerkt den Zustand auf der Liste der Bauelemente. Der Schritt der Inspektion wird für jedes Bauelement dieser Liste wiederholt, bis alle Bauelemente inspiziert wurden. Danach ist die Inspektion abgeschlossen.

2.2 Lebensdauerermittlung von Bauteilen

2.2.1 Einführung

Um die Lebensdauer von Bauteilen zu erläutern, ist das Verständnis für den Lebenszyklus eines Gebäudes notwendig.

Der Lebenszyklus eines Gebäudes wird im Bauwesen in die sogenannten Lebenszyklusphasen (vgl. Kapitel 2.1.2.16) unterteilt. Diese erstrecken sich von der Planung bis zum Rückbau des Objektes. Gemäß der Abbildung 13 lässt sich der Zyklus grob in die Phasen der Planung, des Baus, der Nutzung und des Rückbaus unterteilen.

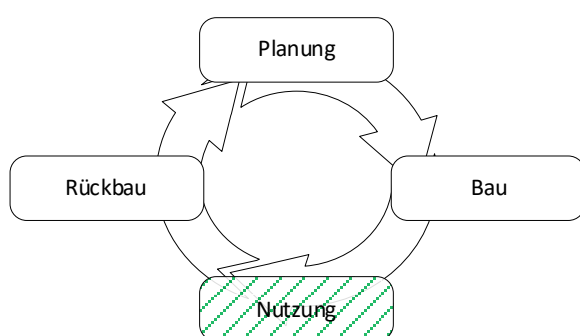


Abbildung 13: Vereinfacht dargestellter Lebenszyklus eines Gebäudes (Quelle: eigene Darstellung)

Die GEFMA hingegen unterteilt in ihrem technischen Regelentwurf 100-1:2004-07 [50] den Lebenszyklus in die folgenden neun Phasen: Konzeption, Planung, Errichtung, Vermarktung, Beschaffung, Betrieb und Nutzung, Umbau/Umnutzung – Sanierung/Modernisierung, Leerstand und Verwertung. Abhängig von der Zielgruppe und dem fachspezifischen Einsatz erfolgt die Unterteilung detaillierter oder gröber. Für diese Arbeit ist eine Grobstruktur in vier Phasen nach Abbildung 13 ausreichend. Die Nutzungsphase, welche in der Abbildung grün hinterlegt ist, beginnt mit der Übergabe an den Nutzer oder Bauherrn und endet mit der Phase des Rückbaus. Zeitlich betrachtet stellt die Phase der Nutzung die längste Phase im Lebenszyklus eines Gebäudes dar [7].

Durch Maßnahmen der Instandhaltung werden die Baukonstruktion und die technische Gebäudeausrüstung während der Nutzung funktionsfähig gehalten. Soweit wie möglich werden die Bauteile instand gehalten, bis sie das Ende ihrer technischen oder wirtschaftlichen Lebensdauer¹⁵ erreicht haben [7].

Bei der Verwendung des Begriffes der Lebensdauer wird in dieser Arbeit ausschließlich von der technischen Lebensdauer gesprochen, eine Prognose von wirtschaftlichen Lebensdauern würde sich insofern als sehr schwierig gestalten, da äußere wirtschaftliche und gesellschaftliche Einflüsse nur sehr schwer oder gar nicht vorhersagbar sind.

¹⁵ Die technische und wirtschaftliche Lebensdauer wird in Kapitel 2.1.2.13 näher erläutert.

Im Gegensatz dazu, obwohl auch die technische Lebensdauer von diversen äußeren Faktoren beeinflusst wird, ist die Prognose einer technischen Lebensdauer unter gewissen Randbedingungen durchführbar. Gerade in Bezug auf Lebenszykluskostenberechnungen ist diese von elementarer Bedeutung. Auf der Basis einer präzisen Prognose der Lebensdauer können Kosten korrekt budgetiert werden und Folgekosten aufgrund zu spät terminierter Instandsetzungsmaßnahmen vermieden werden.

2.2.2 Aktueller Stand der Forschung

Zum Stand der Forschung zur Lebensdauerermittlung von Bauelementen gibt es eine Vielzahl von bereits veröffentlichten Arbeiten. Die meisten Arbeiten beschäftigen sich mit der Thematik der Materialforschung und dementsprechend meistens mit einem ganz spezifischen Bauteil. Arbeiten, die sich mit einem allgemeinen Ansatz oder einer Methodik für eine bauteilübergreifende Lebensdauerermittlung beschäftigen, gibt es nur sehr wenige. Dazu kommt eine Reihe von diversen Veröffentlichungen von Sammlungen und Katalogen von statistischen Lebensdauern, die auf Umfragen, einzelnen Erfahrungswerten oder Hochrechnungen basieren. Das BBSR veröffentlicht dazu regelmäßig Zusammenfassungen in tabellarischer Form verschiedener Autoren.

Eines der umfangreichsten Werke, die sich mit dieser Thematik beschäftigen, ist die Dissertation von Ritter [7], er unterteilte 2011 den damaligen Stand der Forschungen im Bereich der Lebensdauern in die folgenden drei Hauptkategorien:

- „Dauerhaftigkeit von Materialien und Elementen,
- Lebensdauervorhersage und ihre Methoden,
- Instandhaltungsoptimierung.“ [7] (S. 35, 36)

An diesem Stand hat sich bis heute nicht viel getan. In Anlehnung an die Kategorien von Ritter wird für diese Arbeit der aktuelle Stand der Forschungen in die folgenden drei Kategorien unterteilt:

- a. Materialforschung
- b. Methoden zur Lebensdauerprognose
 - Stochastische Methoden
 - Näherungsmethoden
- c. Instandhaltungsoptimierung

Veröffentlichungen aus dem Bereich der Materialforschung (a), die sich mit dem Alterungsverhalten einzelner Bauteile beschäftigen, erscheinen fortlaufend und in regelmäßigen Abständen. Auf einen Überblick dieser Veröffentlichungen wird verzichtet, da die vorliegende Arbeit sich thematisch bei den Methoden zur Lebensdauerprognose (b) einordnet.

Im Bereich der Methoden zur Lebensdauerprognose gibt es einerseits Ansätze, die versuchen auf Basis von stochastischen Methoden die Lebensdauer zu prognostizieren, und andererseits die anwendungsorientierte Näherungsmethoden. Im Bauwesen rechnen sich die hohen Kosten zur Anwendung der stochastischen Methoden meist nicht, weshalb dort überwiegend auf die anwendungsorientierten Näherungsmethoden zurückgegriffen wird [7, 11] und die stochastischen Methoden für einen bauteilübergreifenden Ansatz an Relevanz verlieren. Bei den anwendungsorientierten Näherungsmethoden basiert die Grundidee auf der Ermittlung der

Lebensdauer auf Basis von veröffentlichten statistischen Lebensdauern. In der einfachsten Form, der Kennwertmethode, wird ohne weitere Anpassungen auf einen solchen statistischen Wert zurückgegriffen. Die weiterentwickelte Faktorenmethode nach ISO 15686 bezieht sogenannte Korrekturfaktoren mit der Berechnung ein, um sich stärker der tatsächlichen Lebensdauer, auf Grundlage diverser Einflussfaktoren, anzunähern. Ein ähnliches Verfahren wurde bereits 1995 von Tomm, Rentmeister und Finke [51] veröffentlicht. Im Vergleich zu der im Jahr 2000 veröffentlichten Faktorenmethode nach ISO 15686 besitzt die Faktorenmethode von Tomm, Rentmeister und Finke einen niedrigen Detaillierungsgrad und berücksichtigt nicht die tatsächlichen Umweltbedingungen. Diese Grundidee der ISO 15686 hat sich bis heute in der Forschung als die an der aussichtsreichsten Methode etabliert. In Arbeiten wie von Bahr und Lennerts [11] oder Ritter [7] wird versucht, basierend auf der Faktorenmethode nach ISO 15686, einen optimierten Ansatz für die Prognose von Lebensdauern von Bauteilen zu finden und die Schwächen der Faktorenmethode zu beseitigen.

Im Gegensatz zur klassischen Faktorenmethode, die alle Einflussfaktoren gleich gewichtet, schlagen Bahr und Lennerts eine Differenzierung zwischen Haupt- und Nebeneinflussfaktoren vor und stellen restriktive Vorgaben für die Höhe der Werte für die jeweiligen Einflussfaktoren auf. Außerdem definieren sie eine zweite Bewertungsebene von Einflussfaktoren, um diese weiter differenzieren zu können. Insgesamt wird durch diese Erweiterung die Prognose von Lebensdauern spezifischer Bauteile differenzierbar [7, 11].

Auch Ritter hat in seiner Dissertation die Struktur der Faktoren der herkömmlichen Faktorenmethoden verfeinert. Außerdem erweitert er die ursprüngliche Methode mit einer Wahrscheinlichkeitsverteilung und ermöglicht damit eine präzisere Lebensdauerprognose bei überwiegend unbekanntem Einflussgrößen [7].

Das BBSR empfiehlt (Stand 01/2023) bei der Verwendung der vom BBSR veröffentlichten Lebensdauern für eine projektspezifische Lebenszyklusbetrachtung die Verwendung der Faktorenmethode nach ISO 15686, unter Berücksichtigung des Forschungsberichtes von Bahr und Lennerts [14].

In dieser Arbeit wird für den Bereich der Instandhaltungsoptimierung auf eine Auseinandersetzung mit dem aktuellen Stand der Forschung verzichtet. Der Fokus liegt ausschließlich auf dem Teilbereich der Optimierung der Lebensdauerprognose, nicht auf der Optimierung der Instandhaltung an sich.¹⁶

Aufgrund der essenziellen Bedeutung der ISO 15686 und der dort vorgestellten Faktorenmethoden gibt das nächste Kapitel einen Überblick über die im Jahr 2000 erstmals veröffentlichte internationale Norm.

Den einzelnen Verfahren zur Bestimmung der Lebensdauer wird aufgrund der Bedeutung dieses Themas für diese Arbeit ein eigenes Kapitel (vgl. Kapitel 3) im Hauptteil gewidmet, in dem der aktuelle Forschungsstand zu den verschiedenen Methoden der Lebensdauerbestimmung umfassend behandelt wird.

¹⁶ Optimieren bedeutet in diesem Zusammenhang die Verbesserung der Genauigkeit (Präzisierung).

2.2.3 Norm ISO 15686

Die Normungsarbeit auf dem Gebiet der Lebensdauerplanung von Bauwerken und Bauteilen konzentriert sich im nationalen und internationalen Bereich auf die Überarbeitung bzw. Vervollständigung der ursprünglich¹⁷ elfteiligen Normenreihe ISO 15686.

Aufgrund der in dieser Normenreihe verankerten Faktoren-Methode, ist die ISO 15686 für den Themenbereich Lebensdauerprognose unverzichtbar.

In dieser Arbeit wird darauf verzichtet, auf jeden einzelnen Teil der Norm im Einzelnen genauer einzugehen. Die in mehreren Teilen thematisierte Faktorenmethode wird ausführlich in Kapitel 3.4 erläutert.

Um dem Leser dennoch einen Überblick über die Struktur der Normenreihe ISO 15686 zu geben, zeigt Abbildung 14 den Aufbau und die Beziehungen zwischen den einzelnen Teilen der ISO 15686.




Abbildung 14: Themenbereiche der DIN ISO 15686 zur Lebensdauerplanung von Gebäuden (Stand 03/2023) (Quelle: eigene Darstellung, modifiziert nach [7] S. 37)

Die ursprünglich von Ritter [7] (S. 37) entwickelte Darstellung wurde durch das Entfernen der ISO 15686-6 sowie das Ergänzen der ISO/TR 15681-11 modifiziert, um dem aktuellen Stand zu entsprechen. Außerdem wurde die Bezeichnung von „DIN ISO“ auf „ISO“ geändert, weil eine Übernahme der Norm durch das DIN bis Stand heute nicht stattgefunden hat. Im Weiteren

¹⁷ Der Teil 6 von 2004 wurde mittlerweile zurückgezogen [52], deswegen besteht die Normenreihe nur noch aus zehn Teilen.

wurden auch die Bezeichnungen der Teile 2, 4, 7, 8 und 10 abgeändert. An der Unterteilung in „Datenquellen und Leistungsanforderungen“ sowie „Verfahren und Methoden“ wurde festgehalten.

Die für diese Arbeit relevante Faktoren-Methode wird hauptsächlich im achten Teil der Normenreihe erläutert, in den anderen Teilen wird die Methode lediglich erwähnt, so dass diese hier nicht relevant sind.

Der achte Teil (2008-6) mit dem englischen Originaltitel Buildings and constructed assets - Service life planning: Part 8, Reference service life and service-life estimation (dt.: Referenznutzungsdauer und Bestimmung der Nutzungsdauer), unterteilt sich strukturell in zwei Hauptkapitel.

Im ersten Hauptkapitel „Reference service-life“ (dt.: Referenzlebensdauer) werden die Ansprüche an die Referenzlebensdauern definiert, im zweiten Hauptkapitel „Service-life estimation using the factor method“ (dt.: Lebensdauerermittlung mit der Faktorenmethode) wird die Anwendung der Faktorenmethode zur Berechnung von geschätzten Lebensdauern erläutert [53].

Die Faktorenmethode ermittelt die spezifische Lebensdauer eines Bauteils anhand einer Referenzlebensdauer und Einflussfaktoren, die in der DIN ISO 15686 definiert sind. Die Qualität dieser Ermittlung hängt jedoch von der Qualität der Referenzlebensdauern und der korrekten Gewichtung der Einflussfaktoren ab. Eine ausführliche Erläuterung der Faktorenmethode nach der ISO 15686 befindet sich in Kapitel 3.4.

2.2.4 Alterungsverhalten von Bauteilen

Grundlegend wird bei dem Alterungsverhalten (Abnutzung) von Bauteilen davon ausgegangen, dass diese nicht linear altern. Ritter schreibt diesbezüglich, „dass die Abnutzung im Laufe des Bauteilalters zunimmt“ [7] (S. 41), das Bauteil gegen Ende seiner Lebensdauer folglich schneller altert.

In den DIN-Normen, wie beispielsweise der DIN 31051, wird das Alterungsverhalten von Bauteilen mit einer starken Abbau des Abnutzungsvorrates am Anfang und Ende dargestellt (dargestellt in der Abbildung 15) [4].




Abbildung 15: Grafische Darstellung des Abnutzungsvorrates (Quelle: eigene Darstellung)

Bei der Inbetriebnahme des Bauteils besitzt das Bauteil einen Abnutzungsvorrat von 100 %, im Laufe der Nutzung baut sich dieser aufgrund diverser Einflussfaktoren ab, bis er die Abnutzungsgrenze erreicht hat.

Dieser Verlauf des Abbaus des Abnutzungsvorrates ist von Bauteil zu Bauteil unterschiedlich, so gibt es Bauteile, die in der ersten Hälfte ihrer Nutzungszeit relativ langsam an Abnutzungsvorrat verlieren und in späteren Jahren dann schneller altern, Bauteile, deren Abnutzungsvorrat stetig zunimmt, und Bauteile, die am Anfang ihrer Nutzungsphase schnell altern, ab der Mitte ihrer Nutzungsphase aber langsamer den Abnutzungsvorrat abbauen [7].

Allgemein kann man daher nach Ritter [7] in drei Typen von Bauteilen klassifizieren:

- *Typ I:* Abnutzungsvorrat baut sich am Anfang der Nutzungsphase langsam ab, später sehr schnell.
- *Typ II:* Abnutzungsvorrat baut sich stetig schneller ab.
- *Typ III:* Abnutzungsvorrat baut sich am Anfang und Ende der Nutzungsphase schnell ab, in der Mitte der Nutzungsphase sehr langsam.

Neben dem Verlauf des Alterungsprozesses des Bauteiles über den gesamten Lebenszyklus ist auch der aktuelle Zustand des Bauteiles von Interesse, um bestimmen zu können, in welcher Phase des Alterungsprozesses sich das Bauteil aktuell befindet. In der Literatur wird dafür in den meisten Fällen auf die vier Stufen aus der Dissertation von Krug [54] aus dem Jahr 1985 zurückgegriffen:

- Zustand **A** - Abnutzungsvorrat des Bauteiles liegt bei 85 % bis 100 %,
- Zustand **B** - Abnutzungsvorrat des Bauteiles liegt bei 60 % bis 85 %,
- Zustand **C** - Abnutzungsvorrat des Bauteiles liegt bei 20 % bis 60 %,
- Zustand **D** - Abnutzungsvorrat des Bauteiles liegt bei 0 % bis 20 %.

In der Abbildung 16 werden diese Stufen in der Form einer Skizze dargestellt.

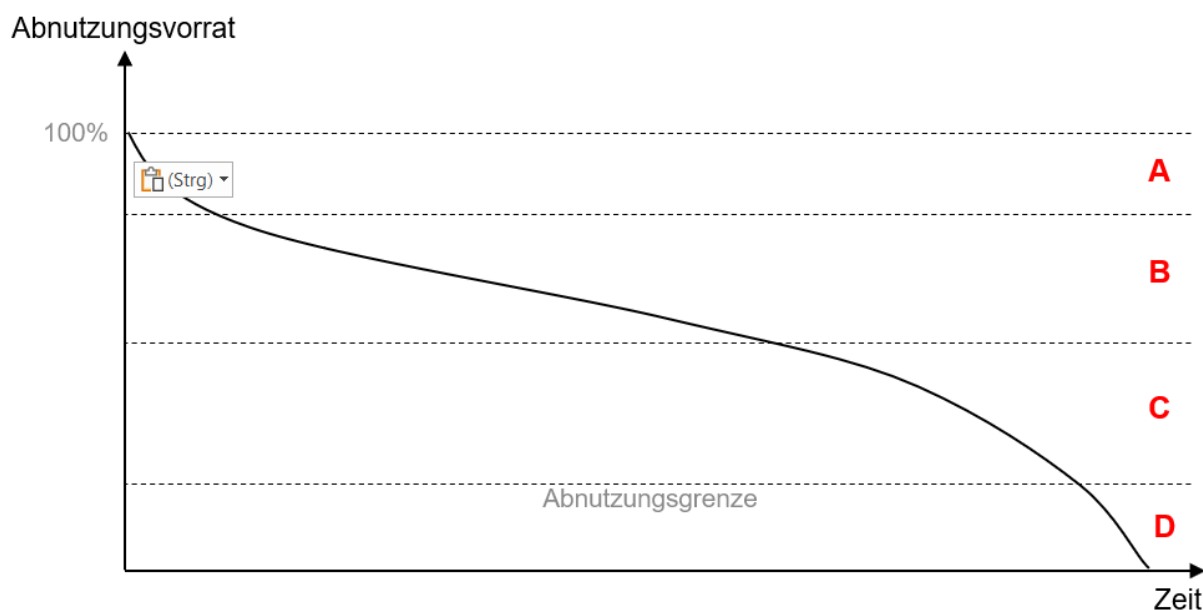


Abbildung 16: Skizze der Klassifizierung nach Krug (Quelle: eigene Darstellung nach [54])

Bahr kritisierte in ihrer Realdatenanalyse [30] im Jahr 2008 bereits, dass Krug die Stufen sehr allgemein definiert, ohne diese auf spezifische Bauteile zu übertragen.

Neben der Arbeit von Krug ist an dieser Stelle als wissenschaftliche Arbeit zur Bauteilalterung auch der Artikel von Schröder aus dem Jahr 1989 mit dem Titel „Zustandsbewertung großer Gebäudebestände“ [6] zu nennen.

Schröder ermittelte für 12 verschiedene Bauteile spezifische Altersentwertungskurven. Für die Ermittlung des Wertverlustes W stellt Schröder folgende Gleichung auf:

$$W = 1 - t^a \quad 2.1$$

(Quelle: [6] S. 452)

Dabei stellt t das Alter des Bauteiles dar und der Exponent a die spezifische Robustheit des Bauteiles. Bei einer linearen Werteentwicklung besitzt a den Wert 1, bei einer beschleunigten Alterung nimmt a einen Wert < 1 ein, im Idealfall ist $a > 1$. Für Schröder steht im Fokus das Entwertungsverhalten von Bauteilen und der Sanierungszeitpunkt. Ein robustes Bauteil ($a = 6$) hat nach Schröder damit gegenüber einem nicht robusten Bauteil ($a = 0,5$) in der Mitte seine Lebensdauer einen wesentlich höheren Wert. Auf Basis dieses Entwertungsverhaltens leitet er vom aktuellen Wert des Bauteiles die Sanierungskosten ab.

Schröder trifft hinsichtlich den Sanierungskosten von Bauteilen eine Aussage, die sich auf die Instandsetzungskosten übertragen lassen: „Eine zu frühe Sanierung ist [...] relativ teuer und wenig sinnvoll.“ [6] (S. 453). Er begründet dies damit, dass der Basisaufwand (z.B. Gerüste und Fahrzeit) unabhängig von der Größe der Maßnahme anfällt. Das Kosten-Nutzen-Verhältnis ist bei frühen Sanierungen schlechter als bei späteren Sanierungen [6].

Weitere Untersuchungen bezüglich des Alterungsverhaltens von Bauteilen wurden im Rahmen des Impulsprogramms Bau [55] des Schweizerischen Bundesamtes für Konjunkturfragen getätigt. Seit den 30er Jahren wurden dafür über 120 verschiedene Wohngebäude (Baujahr 1945 bis Baujahr 1975) untersucht und deren Alterungsverhalten dokumentiert [7].

Die Bewertung des Zustandes erfolgte visuell und mit einem Funktionstest. Als Ergebnis dieser Untersuchung wurden für jedes Bauteil drei Alterungsverläufe entwickelt.

Wie in der Abbildung 17 am Beispiel eines Steildaches¹⁸ dargestellt, gibt es eine Kurve L_{min} , die die Alterung unter den schlechtesten Bedingungen darstellt, eine Kurve L_{max} , die die Alterung unter den besten Bedingungen darstellt, und eine mittlere Kurve L_{\emptyset} .

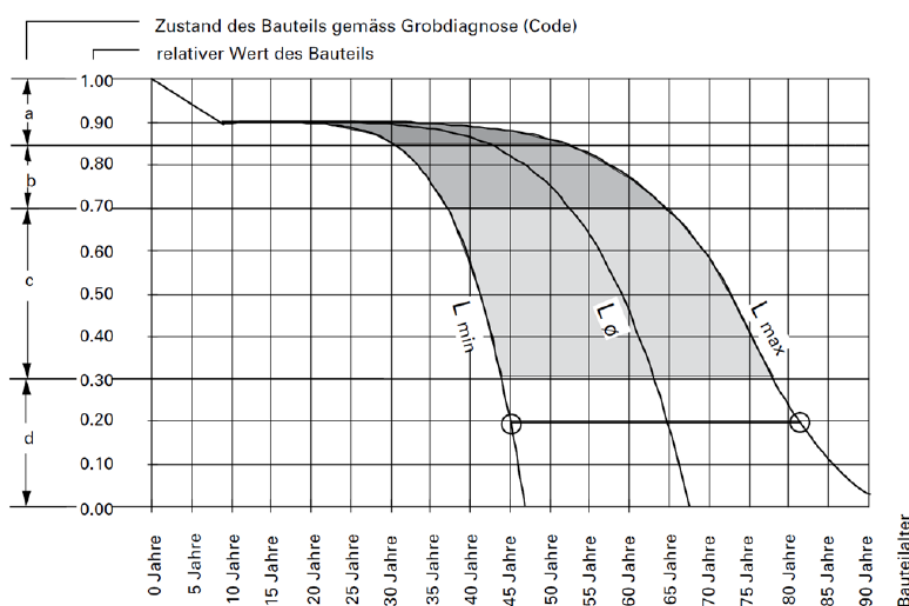


Abbildung 17: Alterungsverhalten und Restlebensdauer am Beispiel Steildach (Ziegel aus Ton)
(Quelle: [7] S. 44 nach [55])

Die verbleibende Lebensdauer von Bauteilen lässt sich mit Hilfe der Diagramme des Impulsprogramms Bau anhand des Bauteilalters und -zustands ermitteln. Die Ungenauigkeit, die aus dieser Zeitspanne resultiert, macht die Werte zur Bestimmung des optimalen Instandsetzungszeitpunktes unbrauchbar.

In aktuellen wissenschaftlichen Arbeiten, wie z.B. von Bahr und Lennerts [11] oder Ritter [7], wird, wie bereits im Kapitel zum aktuellen Stand der Forschung (vgl. Kapitel 2.2.2) erwähnt, versucht, basierend auf der Faktorenmethode nach ISO 15686 ein Berechnungsmodell zu entwickeln, welches durch die Berücksichtigung der entsprechenden Einflussfaktoren und objekt-spezifischen Randbedingungen den spezifischen Alterungsverlauf von Bauteilen genauer ermittelt. Je nach Einflussfaktoren und objektspezifischen Randbedingungen liegt die Lebensdauer des Bauteils über oder unter der durchschnittlichen Lebensdauer.

¹⁸ Bei den untersuchten Steildächern handelt es sich fast ausnahmslos um Dächer aus Tonziegeln.

2.2.5 Zusammenfassung

Zusammenfassend kann gesagt werden, dass Bauteile in der Regel nicht linear altern, sondern dass gegen Ende des Abnutzungsvorrats der Abbau dessen beschleunigt abläuft.

Der genaue Verlauf der Lebensdauer und das damit verbundene Lebensende unterliegen verschiedenen Einflussfaktoren und objektspezifischen Randbedingungen. Diese Einflüsse können sich sowohl positiv als auch negativ auf die Lebensdauer eines Bauteils auswirken, wie in Abbildung 18 grafisch illustriert wird. Dadurch baut sich der Abnutzungsvorrat eines Bauteils schneller bzw. langsamer ab und die ursprüngliche Lebensdauer (b) wird gestreckt (c) bzw. gestaucht (a).

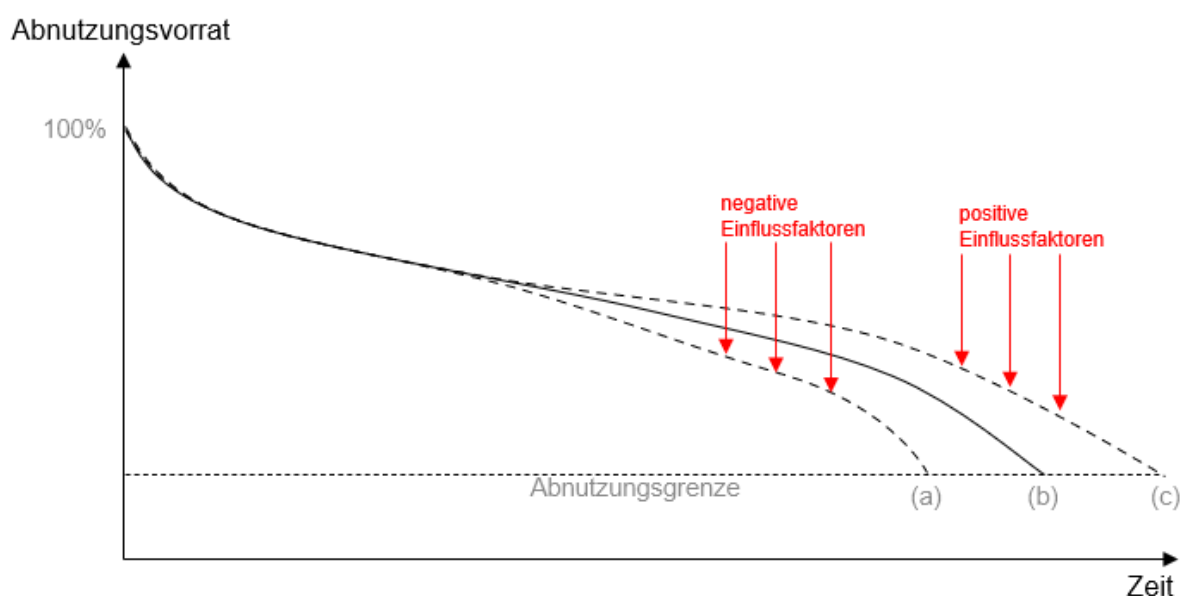


Abbildung 18: Einflussfaktoren beeinflussen das Alterungsverhalten von Bauteilen (Quelle: eigene Darstellung)

Die Faktorenmethode nach ISO 15686, die versucht, diese Einflüsse zu berücksichtigen, ist nach der Literatur die vielversprechendste Methode zur Vorhersage der Lebensdauer von Bauteilen.

Die Norm erläutert diese Methode ausführlich, gibt aber keine konkreten Werte für die Einflussfaktoren an. Theoretisch können diese Werte zwischen Null und Unendlich liegen, wobei Werte größer als Eins die Lebensdauer verlängern und Werte kleiner als Eins die Lebensdauer verkürzen [7].

Bahr und Lennerts [11] sowie Ritter [7] versuchen in ihren Arbeiten mit verschiedenen Ansätzen die Schwachstellen der Faktorenmethode auszubessern.

Das Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen empfiehlt [56] (Stand 01/2023) bei der Verwendung der vom Bundesinstitut für Bau-, Stadt- und Raumforschung veröffentlichten Lebensdauern für eine projektspezifische Lebenszyklusbetrachtung die Verwendung der Faktorenmethode nach ISO 15686, unter Berücksichtigung des Forschungsberichtes von Bahr und Lennerts [14].

2.3 Künstliche Intelligenz

2.3.1 Einführung

Der Begriff der „Künstlichen Intelligenz“ (engl.: Artificial Intelligence) wurde im Jahr 1955 durch den amerikanischen Informatiker John McCarthy (Dartmouth College) in einem Förderantrag geprägt [21].

John McCarthy, Vater des Begriffes der Artificial Intelligence, definierte 1955 den Begriff Künstliche Intelligenz ungefähr laut Ertel [57] etwa so:

„Ziel der KI ist es, Maschinen zu entwickeln, die sich verhalten, als verfügten sie über Intelligenz.“

(Quelle: [57] S. 1)

Es existieren zahlreiche verschiedene Definition der Künstlichen Intelligenz (kurz: KI).

Die europäische Kommission definierte 2018 in ihrem Koordinierungsplan für Künstliche Intelligenz den Begriff der Künstlichen Intelligenz folgendermaßen:

„Künstliche Intelligenz (KI) bezeichnet Systeme mit einem „intelligenten“ Verhalten, die ihre Umgebung analysieren und mit einem gewissen Grad an Autonomie handeln, um bestimmte Ziele zu erreichen. Wir nutzen KI täglich, um beispielsweise unerwünschte E-Mails zu blockieren oder mit digitalen Assistenten zu sprechen.“

(Quelle: [58] S. 1)

Ebenso existierten für die Begriffe „Maschinelles Lernen“ und „Tiefgehendes Lernen“ bis zur Mitte des Jahres 2022 keine konsensfähigen Definitionen. Mit der Veröffentlichung der ISO IEC 23053 und der ISO IEC 22989 versuchte in der Mitte des Jahres 2022 die International Organization for Standardization eine zumindest teilweise genormte Grundlage im Bereich der Künstlichen Intelligenz zu schaffen, lässt bei diesen beiden Erstaufgaben aber einige Klärungspunkte offen oder arbeitet diese nur oberflächlich auf. Die Begriffe „Künstliche Intelligenz“, „Maschinelles Lernen“ und „Tiefgehendes Lernen“ werden oft fälschlicherweise in der Wirtschaft und auch der Forschung synonym genutzt. In der Literatur finden sich zu diesem Bereich unzählige widersprüchliche Aussagen und Abbildungen.

Daher wird in diesem Kapitel versucht Klarheit bezüglich der verschiedenen Begriffe und Ansichten zu schaffen.

Diese Definitionen liegen der vorliegenden Arbeit fortan zu Grunde:

- Definition 1**
- Künstliche Intelligenz (engl.: Artificial Intelligence): **AI**
 - Maschinelles Lernen (engl.: Machine Learning): **ML**
 - Tiefergehendes Lernen (engl.: Deep Learning): **DL**
 - Künstliches neuronales Netz (engl.: Artificial Neural Network): **ANN**

2.3.1.1 Abgrenzung von Machine Learning

Die Differenzierung zwischen Machine Learning und Artificial Intelligence wird sowohl im allgemeinen Sprachgebrauch als auch in der Literatur häufig missverstanden und nicht korrekt verwendet.

Um Artificial Intelligence und Maschine Learning voneinander abgrenzen zu können betrachten wir folgende Aussage von Russel und Norvig [59] aus der aktuellen Version (2010) ihres oft zitierten Werkes „Artificial Intelligence: A Modern Approach“ (Fourth Edition):

„Wir definieren AI als das Lernen von Agenten, die Wahrnehmungen aus der Umwelt empfangen und Handlungen ausführen.“

(Quelle: [59] S. 7, übersetzt aus der englischen Sprache)

Russel und Norvig beziehen sich mit seiner Aussage auf das sogenannte Agenten-Paradigma.

Das Agenten-Paradigma ist eine Sichtweise auf AI, welche die AI als eine Disziplin beschreibt, bei der das Ziel die Entwicklung eines künstlichen Agenten mit rationalem Verhalten ist. In vielen englischen Literaturen wird Artificial Intelligence als die Entwicklung eines solchen intelligenten Agenten (engl.: Intelligent Agent) definiert [59].

Im Agentenparadigma wird klar zwischen dem Agenten und der Umgebung, in der er sich entwickelt, differenziert. Ein AI-Agent interagiert über verschiedene Sensoren und Aktuatoren¹⁹ mit seiner Umgebung und ergreift Maßnahmen, die seine Chancen erhöhen, seine Ziele erfolgreich zu erreichen. Das Agenten-Paradigma ist in der Abbildung 19 dargestellt.

¹⁹ Meist ein Elektromotor oder ein elektromagnetisches Ventil; Umwandlung von Signalen eines Steuergerätes in Bewegung.

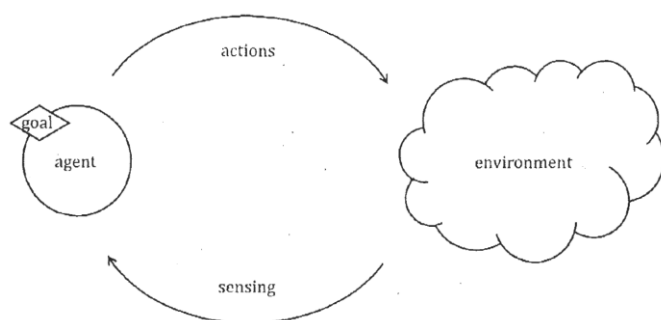


Abbildung 19: Agenten Paradigma (ISO IEC 22989) – goal-based agent (Quelle: [60] S. 18)

Der Agent (in der Abbildung 19) interagiert mit der Umwelt (environment) und führt auf der Basis seiner Ziele (goals) Handlungen (actions) aus.

Amazon Alexa oder Siri von Apple können nach diesem Paradigma als AI-Agenten gesehen werden.

Russel und Norvig [59] unterteilen die Agenten in vier verschiedene Klassen ein, abhängig von dem Level ihrer wahrgenommenen Intelligenz und Fähigkeiten:

- I. „Simple reflex agents,
- II. Model-based reflex agents,
- III. Goal-based agents,
- IV. Utility-based agents.“

[59] (S. 67)

Eine alternative Klassifizierung entwickelte 1999 Gerhard Weiss [61] (S. 42):

- I. „Logic-based agents,
- II. Reactive agents,
- III. Belief-desire-intention agents,
- IV. Layered architectures.“

[61] (S. 42)

In dieser Arbeit werden ausschließlich die unterschiedlichen Klassifikationen genannt. Aufgrund des Umfangs der Thematik wird jedoch auf eine nähere Erläuterung der verschiedenen Agenten verzichtet. Weitere Informationen findet man diesbezüglich in der Literatur von Russel und Norvig [59] sowie Weiss [61].

Die ISO IEC 22989 [60] zitiert im Kapitel „Agent“ die Kategorien von Russel und Norvig [59].

Eine der wohl bekanntesten Schaubilder im Bereich der AI ist die Darstellung der AI mit den Teilbereichen Machine Learning und Deep Learning (vgl. Kapitel 2.3.3.5), wie exemplarisch in der Abbildung 20 dargestellt.




Abbildung 20: Artificial Intelligence (AI) mit den Teilgebieten Machine Learning (ML) und der Teilmenge Deep Learning (DL) (Quelle: eigene Darstellung)

In vielen Literaturen und auf diversen Seiten im Internet zu dem Thema AI wird weiterhin behauptet, dass ML ein Teilbereich der AI ist (vgl. Abbildung 20) [62–64]. Diese Illustration der AI ist vor allem in deutscher Literatur häufig wiederzufinden. Andere Autoren vertreten die Ansicht, dass ML nicht zwingend „intelligent“ sein muss und daher ML und AI nur eine Schnittmenge bilden (vgl. Abbildung 21) [65–67].




Abbildung 21: Artificial Intelligence (AI) mit der Schnittmenge Machine Learning (ML) und der Teilmenge Deep Learning (DL) (Quelle: eigene Darstellung)

Unter Berücksichtigung der Definition von AI aus der Sicht des Agenten-Paradigmas wird ersichtlich, warum viele Autoren mit Darstellungen wie in der Abbildung 20 nicht einverstanden sind. Ein System mit Machine Learning Algorithmen muss nicht zwingend einem Intelligent Agent entsprechen, aber ein Intelligent Agent kann Machine Learning Algorithmen anwenden (vgl. Abbildung 21).

Ähnlich sieht es auch der Internet-Blogger Alfonso R. Reyes [68], der sich mit den verschiedenen Denkweisen und Darstellungen der AI auseinandergesetzt hat. In einem Beitrag auf

seinem Blog stellte er im Dezember 2020 klar, dass ML an sich gar nicht intelligent sein kann, da es keine Eigenschaften eines intelligenten Agenten besitzt. ML-Algorithmen sind daher nicht per se intelligent [68].

„For instance, ML by itself cannot be intelligent because lacks reasoning, planning, logic, and doesn't interact with the environment. ML detects patterns and performs predictions based on statistical analysis of data using math based algorithms. These algorithms are not intelligent per se.“

(Quelle: [68] S. 1)

Reyes sieht den größten Fehler bei den meisten Darstellungen darin, dass sie den Anschein erwecken, dass ML den größten Beitrag zu AI leistet (vgl. Abbildung 20), was ML damit zu einem Teilbereich der AI macht, obwohl ML nur ein unterstützender Zweig der AI ist. Eine Darstellung, die den Anschein erweckt, dass ML den größten Beitrag zu AI leistet und es damit zu ein Teilbereich macht, obwohl ML nur ein beitragender Zweig der AI ist, sei falsch [68].

„The main flaw is that each of the figures makes it look like Machine Learning is the biggest contributor of AI and makes it a subset of AI, when ML is only a contributing branch of AI.“

(Quelle: [68] S. 1)

Die internationale Norm ISO IEC 22989 [60] für Artificial Intelligence verzichtet dabei auf eine derartige Abbildung der Relation zwischen ML und AI und stellt, unter dem Titel „AI ecosystem“, die Relation in einem Schichtenmodell dar (vgl. Anhang A 1).

Eine weitere Unterteilung der AI-Systeme in der Norm erfolgt ausschließlich in die symbolische AI und die subsymbolische AI (vgl. Kapitel 2.3.1.2).

Ergänzend dazu steht in der Norm geschrieben:

„Auf dem Gebiet der AI gibt es viele verschiedene Standpunkte mit unterschiedlichen Paradigmen. Es gibt keine Klassifizierung, die eine eindeutige Unterscheidung zwischen den verschiedenen Arten von AI ermöglicht. Dennoch ist es ist es möglich, einige Dimensionen anzugeben, entlang derer AI-Systeme positioniert werden können.“

(Quelle: [60] S. 19, übersetzt aus der englischen Sprache)

Definition 2 In dieser Arbeit wird ML deswegen als eine technische Komponente für die Umsetzung eines AI-Systems bezeichnet. Für die Beziehung zwischen AI

und ML wird deswegen die Darstellung aus der Abbildung 21 als Grundlage verwendet.

Eine tiefere Auseinandersetzung mit dem Thema Machine Learning befinden sich in Kapitel 2.3.3.

2.3.1.2 Abgrenzung Deep Learning

Deep Learning ist eine Methode des Machine Learning, bei der Artificial Neural Networks (vgl. Kapitel 2.3.3.4) mit zahlreichen Zwischenschichten (engl.: Hidden layers) eingesetzt werden.

In der Abbildung 22 sind, ergänzend zu der Abbildung 21, die Zusammenhänge zwischen dem Machine Learning und dem Deep Learning grafisch illustriert.




Abbildung 22: Zusammenhänge zwischen Machine Learning und Deep Learning (Quelle: eigene Darstellung)

Deep Learning kann, wie aus der Abbildung 22 ersichtlich, als Gruppe bestimmter Machine Learning Algorithmen verstanden werden und widerspricht damit nicht der **Definition 2**, dass Deep Learning ein Teilbereich des Machine Learning ist.

Weiterführende Erläuterungen befinden sich zu Thema Deep Learning in Kapitel 2.3.3.5.

2.3.1.3 Symbolische und Subsymbolische AI

Die Norm ISO IEC 22989 [60] differenziert zwischen den beiden konkurrierenden AI Paradigmen: die symbolische AI sowie die subsymbolische AI [60].

- **Symbolische AI**

Der symbolische Ansatz wird auch als der klassische Ansatz der AI bezeichnet, hier wird das Problem vollständig abgebildet und ein Computer leitet sich die Antwort aus logischen Regeln ab. Alle Eventualitäten müssen dabei durch ein vorher definiertes Regelwerk abgedeckt sein. Ein Beispiel für diesen Ansatz ist der Schachcomputer Deep Blue von IBM aus dem Jahr 1997.

- **Subsymbolische AI**

Angetrieben durch den technischen Fortschritt, die Verfügbarkeit immer größerer Datenmengen und die sich daraus ergebenden neuen Möglichkeiten hat sich in den

letzten 20 Jahren ein statistikbasierter Ansatz entwickelt. Im Gegensatz zum symbolischen Ansatz lernt die subsymbolische AI aus Erfahrungen und Beispielen und erkennt selbstständig Muster und darauf basierende Regeln. Beispiele für solche Ansätze sind Hidden Markov Modelle oder Machine Learning Systeme mit Algorithmen wie dem Entscheidungsbaumverfahren oder künstlichen neuronalen Netzen.

Moderne Systeme der Künstlichen Intelligenz enthalten in der Regel sowohl Elemente der symbolischen KI als auch Elemente der subsymbolischen AI. Solche Systeme werden als hybride AI-Systeme bezeichnet [60].

2.3.1.4 Philosophische Betrachtung

Aus der philosophischen Sicht ist die Erschaffung von Maschinen, die über eine Intelligenz verfügen, sehr umstritten [60].

In dieser philosophischen Debatte haben sich zwei neue Begriffe, die „weak AI“ (dt.: schwache KI) und die „strong AI“ (dt.: starke KI), herausentwickelt. Die schwache AI definiert sich dabei als ein System, das Daten verarbeiten kann, aber nicht versteht, was es tut. Bei der starken AI hingegen versteht das System, was es wirklich tut. Während diese beiden Kategorien für eine philosophische Auseinandersetzung mit dem Thema AI wichtig sind, spielt die Unterscheidung nach Verständnisaspekten für eine technische Auseinandersetzung, wie sie in dieser Arbeit erfolgt, keine wesentliche Rolle.

Weitere Begriffe, die bei diesen Debatten auftauchten, sind die *narrow* (dt.: enge) AI und *general* (dt.: allgemeine) AI. Die *narrow AI* beschreibt dabei ein AI-System, das speziell für das Lösen eines expliziten Problems entwickelt wurde und auch ausschließlich nur dieses eine Problem lösen kann. Im Gegensatz dazu kann die *general AI* für die Lösung von universellen Problemen eingesetzt werden und liefert für alle Probleme eine zufriedenstellende Lösung. Stand Januar 2023 existieren ausschließlich *narrow AI*-Systeme, ob die Entwicklung eines *general AI*-Systems überhaupt technisch umsetzbar ist, ist nicht absehbar [60].

2.3.1.5 Ergänzende Erläuterungen

Wenn über AI gesprochen wird, dann handelt es sich ausschließlich um spezifisch konzipierte AI-Module, die individuell für einen ganz konkreten Anwendungsfall entwickelt wurden [69][70]. Es gibt viele Problemstellungen, die mit Hilfe solcher AI-Module gelöst werden können. Eine Auflistung bekannter Problemtypen und deren Algorithmen folgt im Kapitel 2.3.2.

Im Kontext von AI wird auf ein eigenes Kapitel für detaillierte Begriffserklärungen verzichtet. Im Gegensatz zur Instandhaltung, wo einige Begriffe in der Umgangssprache konträr zur Festlegung in den Normen verwendet werden und dadurch die Definitionen teilweise unklar sind, sind die meisten Begriffe im Bereich der AI sehr eindeutig.

Notwendige Erläuterungen zur AI werden an der entsprechenden Stelle im Kapitel eingeschoben. Für einen umfassenden Überblick über die Terminologien der AI kann die ISO IEC 22989 [60] herangezogen werden, welche im Juli 2023 in der ersten Version unter dem englischen Titel „Information technology – Artificial intelligence – Artificial concepts and terminology“ durch die Internationale Organisation für Normung publiziert wurde.

2.3.2 AI-spezifische Problemdefinitionen

2.3.2.1 Einleitung

Das vorliegende Kapitel beschäftigt sich mit den spezifischen Problemdefinitionen im Bereich AI. Insbesondere werden die bekanntesten Herausforderungen behandelt, bei denen der Einsatz von AI als Lösungsansatz in Betracht gezogen wird.

2.3.2.2 Clustering

Clustering (dt.: Gruppierung) bedeutet, dass Datenpunkte auf der Grundlage ihrer Ähnlichkeit gruppiert werden. Clustering kann beispielsweise eingesetzt werden, um die Nutzer einer Bankkarte auf der Grundlage ihres Kaufverhaltens in Gruppen einzuteilen.

Der bekanntester Cluster-Algorithmus in der Clusteranalyse ist der K-means-Clustering-Algorithmus [71]. Ziel ist es dabei, den Datensatz so in k Gruppen aufzuteilen, dass die Summe der quadrierten Abweichungen vom Mittelpunkt der Cluster minimal ist. Vereinfacht ausgedrückt werden ähnliche Objekte einer Menge gruppiert, wobei die Anzahl der Gruppen durch k vorgegeben ist.

In der Abbildung 23 ist eine Clustering beispielhaft illustriert.

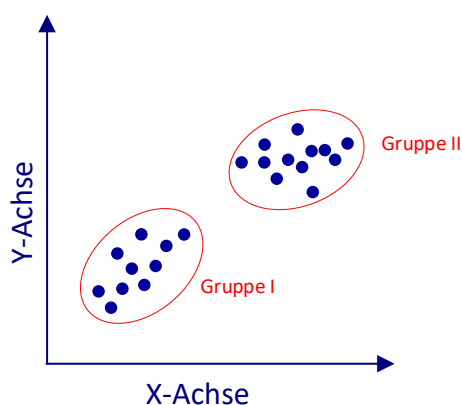


Abbildung 23: Beispiel für eine Clusterbildung (K-means-Clustering) (Quelle: eigene Darstellung)

Weitere bekannte Cluster-Algorithmen sind der *Mean Shift Clustering-Algorithmus* und der *Density-based Clustering-Algorithmus* [71].

2.3.2.3 Computer Vision und Bilderkennung

Die beiden Bereiche „Computer Vision“ und „Bilderkennung“ sind eng miteinander verknüpft. Computer Vision beschreibt die Erfassung, Verarbeitung und Interpretation von Bildern oder Videos, während Bilderkennung ein Klassifikationsverfahren ist, bei dem Objekte, Muster oder Inhalte in einem Bild klassifiziert werden [60].

Diese Technik wird z.B. bei automatischen Nummernschild-Scannern im Straßenverkehr oder bei Software zur Gesichtserkennung eingesetzt. Die zugrunde liegende Problemstellung besteht darin, auf einem Bild Nummernschilder bzw. Gesichter zu klassifizieren (Objekt wird der Klasse Nummernschild/Gesicht zugeordnet).

2.3.2.4 Erkennung von Anomalien

Hierbei geht es um die Identifikation von Datenpunkten, die nicht dem allgemein erkannten Muster entsprechen. Diese Punkte werden als sogenannte Ausreißer (engl.: Outlier) bezeichnet. Ein Beispiel ist in der Abbildung 24 zu sehen [71].

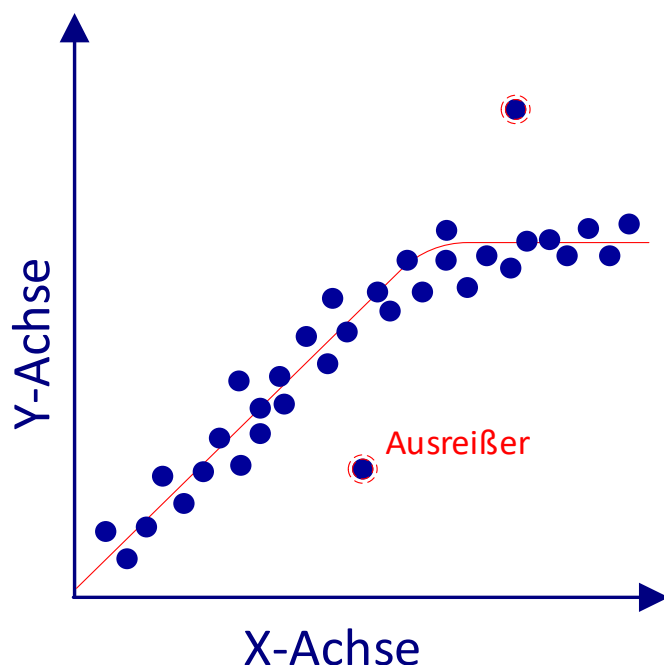


Abbildung 24: Ausreißer (Outlier) am Beispiel einer Regression (Quelle: eigene Darstellung)

Zum Einsatz kommt die Erkennung von Anomalien zum Beispiel, um auffällige Banktransaktion zu erkennen, die nicht zum gewöhnlichen Muster des Nutzers passen.

2.3.2.5 Klassifizierung

Klassifizierung ist der Prozess der Vorhersage, zu welcher Kategorie oder Klasse ein spezifischer Datenpunkt gehört. Bei einer Eingangsvariable (x) soll das Modell über eine Abbildungsfunktion (f) approximativ die Ausgangsvariable (y) ermitteln. Ein Klassifizierungsmodell könnte beispielsweise dazu verwendet werden, um vorherzusagen, ob es sich bei einer E-Mail um Spam handelt oder nicht. Eingehende E-Mails werden der Klasse „Spam“ oder „kein Spam“ zugeordnet. Außerdem könnte ein Klassifizierungsmodell bei Bildern entscheiden, ob es sich um einen Menschen auf dem Bild handelt oder ein Tier [71].

Die Klassifizierung gehört zur Kategorie supervised learning (siehe Kapitel 2.3.3.2.1 Supervised Learning), grundsätzlich wird hier zwischen zwei Methoden des Lernens differenziert:

- **Lazy Learning** (engl.: „Träges Lernen“)

Lazy Learning ist eine Lernmethode, bei welcher der Aufbau des Modells theoretisch so lange hinausgezögert wird, bis eine Vorhersage benötigt wird [72]. Das Modell baut sich schrittweise auf, sobald neue Daten zur Verfügung stehen. Diese Art des Lernens ist in der Regel effizienter, aber möglicherweise weniger präzise in den Ergebnissen als

Eager Learning. Beispiele für Algorithmen sind: K-Nearest-Neighbor, Case-based reasoning (CBR) [71, 73].

Der Ansatz, das Modell inkrementell aufzubauen, ermöglicht das flexible Reagieren auf sich ständig ändernde Datensätze.

- **Eager Learning** (engl.: "Eifriges Lernen")
Lazy Learning-Algorithmen konstruieren im Gegensatz dazu das Modell auf der Grundlage der gegebenen Trainingsdaten. Das Modell hält damit an der anfangs aufgestellten Hypothese kontinuierlich fest. Der Zeitaufwand für das Training ist größer als beim Lazy Learning, die Vorhersagezeit wird aber deutlich verkürzt. Beispiele für Algorithmen sind: Entscheidungsbäume, Naive Bayes, Künstliche Neuronale Netze [71, 74].

2.3.2.6 Optimierung

Bei der Optimierung wird versucht einen möglichst optimalen Parameter eines Systems zu finden. Optimal bedeutet dabei, dass eine Zielfunktion, auch Fehlerfunktion genannt, maximiert oder minimiert wird. Häufig ist man ausschließlich an Werten interessiert, die zusätzlich Nebenbedingungen erfüllen. Diese Nebenbedingungen werden in der Form einer Gleichung, Ungleichung oder einer expliziten Menge beschrieben. Ein Beispiel für Nebenbedingungen wären nur ganzzahlige Werte.

Dabei werden die Optimierungsalgorithmen in verschiedenen Ordnungen klassifiziert:

Algorithmus der nullten Ordnung

Algorithmen der nullten Ordnung kommen zum Einsatz, wenn die Informationen über den Gradienten oder die Hesse-Matrix schwierig zu berechnen sind bzw. wenn es keine explizite Funktion gibt oder die Funktion nicht differenzierbar ist [75].

Algorithmus der ersten Ordnung

Algorithmen der ersten Ordnung sind aktuell die am meisten eingesetzten Optimierungsalgorithmen. Diese sind geeignet für große Datenmengen mit einem geringeren Anspruch an die Genauigkeit [75]. Die Anforderungen werden dabei an die erste Ableitung der Funktion gestellt. Der am häufigsten eingesetzte Optimierungsalgorithmus der ersten Ordnung ist der (stochastische) Gradientenabstieg (engl.: Stochastic gradient descent: SGD) [71].

Algorithmus der zweiten Ordnung

Algorithmen der zweiten Ordnung werden eingesetzt, wenn der Anspruch einer hohen Genauigkeit vorliegt [75]. Die Anforderungen werden dabei an die zweite Ableitung der Funktion gestellt. Die Hesse-Matrix dient dabei als Sammlung der zweiten partiellen Ableitungen [71].

2.3.2.7 Regression

Die Regression ist eine statistische Methode zur Modellierung der Beziehung zwischen einer oder mehreren unabhängigen Variablen (Prädiktoren) und einer abhängigen Variablen (Kriterium). Das Ziel ist es zu verstehen, wie sich der Wert der abhängigen Variable ändert, wenn die Werte der unabhängigen Variablen sich ändern. Die gebräuchlichste und einfachste Form

der Regression ist die einfache lineare Regression, bei der die Beziehungen zwischen den Variablen linear sind, d.h., die Veränderungen der abhängigen Variable sind konstant und proportional zur Veränderung der unabhängigen Variable. Das Modell wird durch eine lineare Gleichung dargestellt:

- einfache lineare Regression, lineare Funktion $y = a + b * x$

b = Regressionsgewicht, Steigung der Regressionsgeraden,

a = y-Achsenabschnitt der Regressionsgeraden.

Regressionsmodelle, die lediglich eine unabhängige Variable beinhalten, werden als einfache Regressionsmodelle bezeichnet, bei zwei oder mehr unabhängigen Variablen spricht man von der multiplen Regression [71]. In der Realität muss bei Regressionsproblemen oft eine Vielzahl von Prädiktoren berücksichtigt werden.

Die Funktion der (einfachen) linearen Regression: $y = a + b_0 * x_0$ (eine unabhängige Variable), im Vergleich dazu die Funktion der (multiplen) linearen Regression: $y = a + b_0 * x_0 + b_1 * x_1 + b_2 * x_2 + b_3 * x_3$ bei vier unabhängigen Variablen.

Außer der Regression auf Basis der Linearfunktion gibt es viele weitere nicht-lineare Regressionen, die auf entsprechende mathematische Funktionen basieren, beispielsweise:

- einfache exponential-Regression, Exponentialfunktion $y = a * b^x$,
- einfache logarithmische Regression, logarithmische Funktion $y = \ln(x)$,
- einfache polynomiale Regression, Polynomfunktion $y = a * x^2 + b * x + c$,
- usw.

In unterschiedlichen Domänen wie der Wirtschaft, den Finanzen und dem Marketing findet die Regressionsanalyse umfassende Anwendung, indem sie die Beziehungen zwischen Variablen erforscht und Prognosen ermöglicht.

2.3.2.8 Verarbeitung natürlicher Sprache (NLP)

Natural Language Processing (NLP) ist ein Zweig der künstlichen Intelligenz, der sich auf die Interaktion zwischen Mensch und Computer mittels natürlicher Sprache konzentriert. NLP zielt darauf ab, menschliche Sprache so zu verstehen, dass sie von Computern verarbeitet werden kann.

Eine derzeit sehr bekannte Anwendung, mit über 1,4 Milliarden Nutzern [76], ist der Chatbot ChatGPT in der Version 3.5 bzw. 4.0 [77].

Chatbots sind Programme, die eine Konversation mit einem Benutzer aufbauen können. Sie werden häufig im Kundenservice, Marketing und Support eingesetzt. Chatbots verwenden NLP, um die Eingaben des Benutzers zu verstehen und angemessen zu antworten. Ziel ist es, ein menschenähnliches Gespräch mit dem Nutzer zu führen, um eine effektive Interaktion zu gewährleisten. NLP und Chatbots haben eine Vielzahl von Anwendungen und können in vielen Branchen eingesetzt werden, um die Interaktion mit Kunden oder Nutzern zu verbessern.

Der Chatbot ChatGPT ist nur eines von vielen Beispielen, wie NLP und künstliche Intelligenz eingesetzt werden können, um eine menschenähnliche Konversation zwischen Mensch und Maschine zu ermöglichen.

AI-Systeme, mit denen auf scheinbar professionelle und kreative Weise alle möglichen Ergebnisse produziert werden können, werden unter dem Begriff der Generativen AI zusammengefasst [78].

Diese Generative AI, auch bekannt als generatives Deep Learning oder generative neuronale Netze, ist ein Teilgebiet der künstlichen Intelligenz, das Deep-Learning-Modelle verwendet, um neue und originelle Daten zu erzeugen, die den Eingabedaten ähneln, auf denen sie trainiert wurden. Dazu gehören neben Anwendungen, die Texte erzeugen, auch Anwendungen, die Bilder, Musik oder auch Videos generieren. Ein Beispiel für ein AI-Modell, das aus einem Text ein Bild erzeugt, ist Stable Diffusion 1.5 bzw. das darauf basierende Modell Dreamlike Photoreal 2.0. Die in der Abbildung 25 und Abbildung 26 abgebildeten Frauen sind nicht existent, sie wurden mit dem KI-Modell Dreamlike Photoreal 2.0 erstellt.



Abbildung 25: Foto einer Frau, erzeugt durch eine AI (Quelle: eigene Darstellung)



Abbildung 26: Foto einer Frau, erzeugt durch eine AI (Quelle: eigene Darstellung)

Für die Erstellung der Abbildung 25 wurde der AI der folgenden Text übergeben: „photo of a 20 years old average looking woman, pale skin, student sitting in munich, full body, blonde hair, detailed skin, detailed face“. Die Abbildung 26 wurde durch den folgenden Text generiert: „photo of a 20 years old good looking woman, pale skin, student sitting in munich, upper body, blonde hair, detailed skin, detailed face“

Bei beiden Abbildungen wurde auf den Sampler DPM++ 2S a Karras zurückgegriffen.

2.3.3 Machine Learning

Nach der Abgrenzung des Begriffes Machine Learning im Kapitel 2.3.1.1, erfolgt in diesem Abschnitt eine vertiefende und technisch orientierte Betrachtung der Thematik

Machine Learning ist eine häufig genutzte technische Komponente im Bereich der Artificial Intelligence und bietet eine alternative Methode zum herkömmlichen Programmieransatz. Viele Ansätze die heutzutage als Artificial Intelligence betitelt werden, sind tatsächlich „nur“ Machine Learning und oft weniger intelligent.

In einer Potenzialanalyse [79] bezeichnet die Fraunhofer-Allianz BIG DATA Machine Learning als die Kerntechnologie der Künstlichen Intelligenz. Im Gegensatz zu dem herkömmlichen Ansatz der Programmierung, bei dem durch statische und explizite Berechnungsvorschriften eine Ausgabe erzeugt wird, also die Problemlösung vorher modelliert und implementiert werden muss, wird bei Machine Learning auf der Grundlage von Beispieldaten gearbeitet. Es basiert auf der Idee, dass Maschinen aus Daten Muster erkennen, lernen und daraus Entscheidungen oder Vorhersagen treffen können, ohne dass vorher die Problemlösung mathematisch modelliert werden musste. Dieses entwickelte Modell kann dann neue, ungesehene Daten verarbeiten und dafür ebenfalls Entscheidungen oder Vorhersagen ableiten.

Seit Juni 2022 sind in der Norm ISO/IEC 23053 die Rahmenbedingungen und Grundlagen für Systeme der Artificial Intelligence basierend auf Machine Learning festgeschrieben. Die Norm wird in den Grundlagen ausführlich erörtert, da die Entwicklung des neuronalen Modells (vgl. Kapitel 9.3) maßgeblich auf den theoretischen Prinzipien dieser Norm basiert.

2.3.3.1 System ML nach ISO/IEC 23053

Das System Machine Learning wird nach der ISO/IEC 23053 [80] in vier Komponenten unterteilt: Tasks (a), Model (b), Data (c), Tool and techniques (d). In diesem Kapitel werden dem Leser der theoretische Aufbau dieses Systems und die darin enthaltenden Komponenten erläutert. Bei der Erläuterung der Komponenten wird in diesem Grundlagenkapitel nur bis zu einem gewissen Detaillierungsgrad eingegangen. Sind für das Verständnis weitere Informationen notwendig, werden diese an den entsprechenden Stellen im Hauptteil ergänzt. Die grafische Darstellung dieses Systems kann der Abbildung 27 entnommen werden. Dabei ist darauf hinzuweisen, dass die Abbildung sich nicht als vollständig versteht, sondern lediglich den Aufbau und die Zusammenhänge in dem System Machine Learning verdeutlichen soll.




Abbildung 27: Elemente des Systems "Machine Learning" nach ISO/IEC 23053:2022 (Quelle: eigene Darstellung nach [80] S.5)

2.3.3.1.1 (a) Task (problem definition)

(dt.: Aufgabe bzw. Definition des Problems)

Bekannte Beispiele für Probleme, die mit ML gelöst werden können, sind [80] (S. 5 ff.):

- Regression,
- Classification,
- Clustering,
- usw.

Weitere Beispiele, mit umfänglicher Erläuterung, befinden sich im Kapitel 2.3.3.2.

2.3.3.1.2 (b) Model

(dt.: Modell)

Ein mathematisches Konstrukt, das eine Inferenz oder Vorhersage auf der Grundlage von Eingabedaten oder Informationen erzeugt. Das ML-Modell umfasst eine Datenstruktur und eine Software zur Verarbeitung der Struktur, die beide durch einen gewählten ML-Algorithmus bestimmt werden. Das Modell ist mit Eingaben und Ausgaben konfiguriert, die für die Lösung des gegebenen Problems wesentlich sind.

Übersetzt in die deutsche Sprache aus der Norm ISO/IEC 23053 [80] (S. 7).

2.3.3.1.3 (c) Data

(dt.: Daten)

Die Daten werden nach der ISO/IEC 23053 [80] (S. 8 ff.) in vier gegenseitig einzigartigen Kategorien unterteilt:

- a. Training dataset (dt.: Trainingsdaten): Datensatz zum Trainieren des Modelles.
- b. Validation dataset (dt.: Validierungsdaten): Datensatz zum Abstimmen der Hyperparameter²⁰.
- c. Test dataset (dt.: Testdaten): Datensatz für die Bewertung der endgültigen Modelleistung.
- d. Production data (dt.: Produktionsdaten): Daten aus einem produktiven Umfeld (Anwendung des Modells). Production data können bezüglich der Struktur oder dem Inhalt leicht von den bei der Entwicklung verwendeten Datensätzen abweichen, daher ist die Prüfung des Modells mit realen Datensätzen zwingend notwendig.

2.3.3.1.4 (d) Tools and techniques

(dt.: Werkzeuge und Techniken)

Die Werkzeuge und Techniken werden nach der ISO/IEC 23053 [80] (S. 9 ff.) in die folgenden Punkte unterteilt:

- a. Data preparation: die Datenaufbereitung wird in Kapitel 2.3.3.3 behandelt.

²⁰ Der Begriff Hyperparameter beschreibt alle Merkmale eines ML-Algorithmus die den Lernprozess beeinflussen [60]. Die Hyperparameter werden vor dem Training des Modelles eingestellt. Beispiele für Hyperparameter sind: Anzahl der Netzwerkschichten, Größe der Schichten, Art der Aktivierungsfunktion, (...).

- b. Categories of ML algorithms: eine Übersicht über verschiedene Kategorien von ML-Algorithmen kann der Abbildung 22 sowie Anhang A 2 entnommen werden. Auf die Kategorie der Künstlichen Neuronalen Netze wird aufgrund ihrer Relevanz für diese Arbeit in einem eigenen Kapitel näher eingegangen.
- c. Optimization methods: Methoden zur Anpassung des Modelles an die Daten (vgl. Kapitel 2.3.3.6).
- d. Evaluation metrics: Metriken zur Bewertung der Ergebnisse des Modells (vgl. Kapitel 2.3.3.6).

2.3.3.2 Ansätze

Machine Learning unterteilt sich nochmals in die folgenden drei Ansätze bzw. Methoden [81]:

- überwachtes Lernen (engl.: supervised learning),
- unüberwachtes Lernen (engl.: unsupervised learning),
- verstärkendes Lernen (engl.: reinforcement learning).

Neben diesen primären Ansätzen gibt es in der Literatur eine Vielzahl von Unterkategorien und Mischformen wie beispielweise halbüberwachte Lernen (engl.: semi-supervised learning). Mit jedem dieser Ansätze können verschiedene Probleme (engl.: Tasks) gelöst werden.

Eine Übersicht der Ansätze bzw. Methoden und eine Zuordnung der Tasks und einsetzbaren Logarithmen bietet die ISO/IEC 23053 auf der Seite 19 (vgl. Abbildung 28).

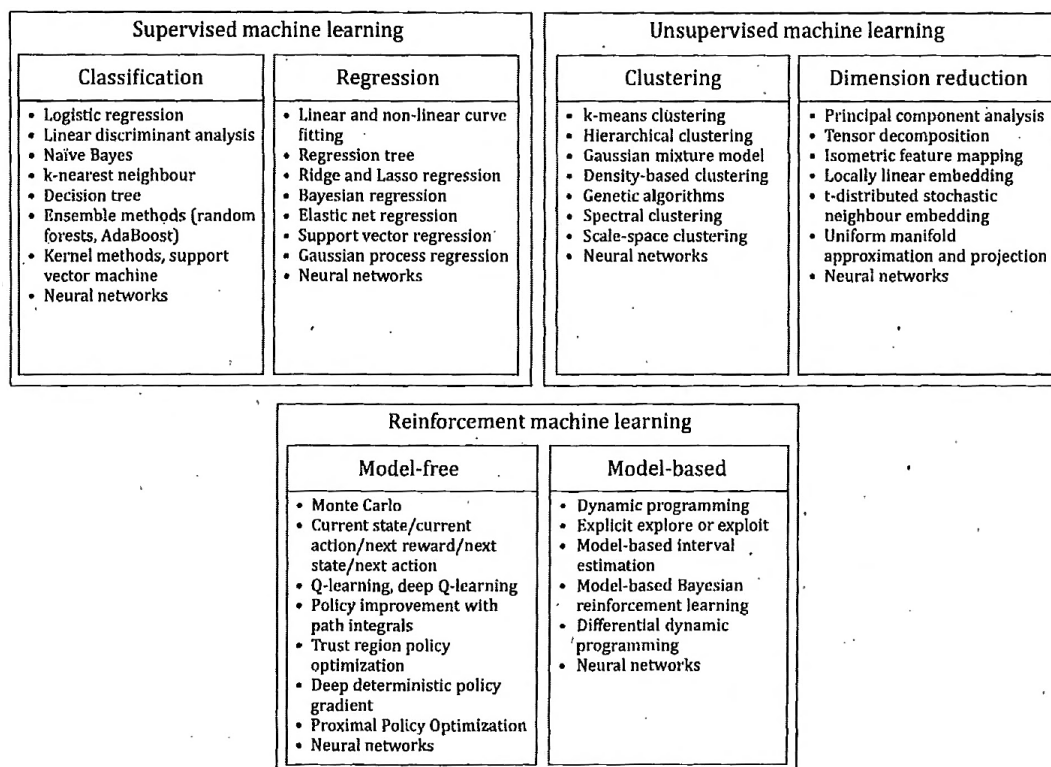


Abbildung 28: ML-Methoden, kategorisiert als supervised ML, unsupervised ML und reinforcement ML nach der ISO/IEC 23053 (Quelle: [80] S. 19)

2.3.3.2.1 Supervised Learning

Das überwachte Lernen ist die einfachste Methode der drei Kategorien [71]. Beim überwachten Lernen wird das Modell auf der Grundlage von Daten trainiert, die bereits beschriftet sind (engl.: Labeled data), was bedeutet, dass die Daten sowohl Eingabedaten (engl.: Features) als auch die entsprechenden korrekten Ausgabedaten (engl.: Labels) enthalten. Eine ausführliche Erläuterung des Begriffes „labeled data“ enthält das Kapitel Datenaufbereitung 2.3.3.3.

Hinsichtlich der Datenaufbereitung (vgl. Kapitel 8.2) ist es wichtig, zwischen den verschiedenen Skalenniveaus²¹ der Features zu differenzieren:

Categorical/Nominal Feature (dt.: Kategorische bzw. nominale Eingabedaten): Kategorien wie wahr, falsch oder rot, grün und blau. Die Reihenfolge spielt bei kategorischen Daten keine Rolle.

Metric/Quantitative/Numeric Feature (dt.: Metrische, quantitative oder numerische Eingabedaten): Numerische Werte wie Alter, Gehalt oder Regenmenge.

Ordinal Feature (dt.: Ordinale Eingabedaten): Sortierte Kategorien wie beispielsweise Schulnoten, bei denen die Reihenfolge eine Rolle spielt.

Weitere Erläuterungen finden sich im Kapitel 8.4.

In der Abbildung 29 ist die Erstellung eines ML-Modells mit Supervised Learning schematisch illustriert.




Abbildung 29: Erstellung eines ML-Modells mit Supervised ML (Quelle: eigene Darstellung nach [80] S. 21)

Beim überwachten Lernen lernt das Modell die Zuordnung zwischen Eingabe- und Ausgabedaten und kann diese Zuordnung auf unbekannte Eingabedaten anwenden.

Im ersten Schritt des supervised learnings trainiert das Modell ausschließlich mit dem Trainingsdatensatz, dabei lernt das Modell aus den Daten das Muster und passt die Gewichte der Algorithmen an. Im zweiten Schritt durchläuft es eine weitere Trainingsrunde gegen den

²¹ Manchmal wird in der Literatur das Skalenniveau auch als Skalendignität oder Messniveau bezeichnet. In dieser Arbeit wird die Bezeichnung Skalenniveau verwendet.

Validierungsdatensatz. Dieser Schritt ist für die Abstimmung der Hyperparameter (daher für künstliche neuronale Netzwerke, siehe Kapitel 2.3.3.4) eines Modells notwendig. Nach der Anpassung der Hyperparameter durchläuft das Modell nochmals den kompletten Trainingsprozess gegen den Trainingsdatensatz, mit den modifizierten Hyperparametern. Im letzten Schritt wird das trainierte Modell, das die beste Performance bei dem Validierungsdatensatz hatte, mit dem Testdatensatz evaluiert. In diesem letzten Schritt erfolgt keine weitere Anpassung des Modelles, hier wird ausschließlich getestet, wie hoch die Qualität des Modelles bei unbekanntem Daten ist.

Der Ablauf dieses Trainingsprozesses ist in der Abbildung 30 detailliert abgebildet.

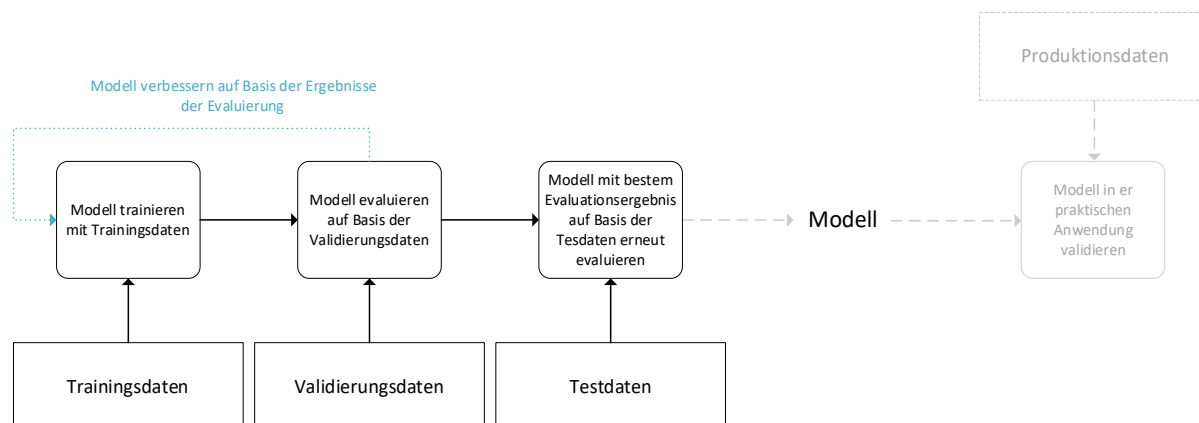


Abbildung 30: Ablauf des Trainings eines Modells (Supervised Learning) (Quelle: eigene Darstellung)

Nachdem das Modell in einer produktiven Umgebung implementiert wurde, erfolgt eine erneute Validierung mit realen Datensätzen. Dieser Prozess ist gesondert zur ursprünglichen Trainingsphase des Modelles zu betrachten. Eine erneute Validierung findet Anwendung, insbesondere wenn angenommen wird, dass die Struktur oder der Inhalt der beim Training verwendeten Datensätze abweichen könnte.

Anwendung findet das Supervised Learning vor allem bei Problemstellung wie der Klassifizierung, der Computer Vision und Bilderkennung sowie der Regression. Aber auch bei vielen weiteren Problemstellungen kann Supervised Learning zum Einsatz kommen.

2.3.3.2 Unsupervised Learning

Unüberwachtes Lernen ist eine Art des Machine Learning, bei dem das Modell keine Trainingsdaten erhält und selbständig Muster in den Daten finden muss. Dem Modell werden also ausschließlich unbeschriftete Daten (engl.: unlabeled data) übergeben und das Modell muss die Muster selbst identifizieren. In der Abbildung 31 ist die Erstellung eines solchen ML-Modelles mit Unsupervised Learning schematisch dargestellt.

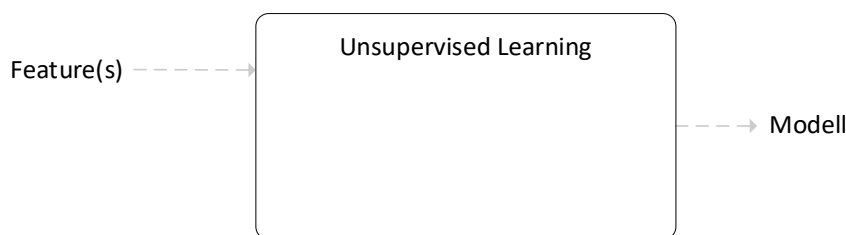


Abbildung 31: Erstellung eines ML-Modells mit Unsupervised ML (Quelle: eigene Darstellung nach [80] S. 22)²²

Unsupervised Lernalgorithmen werden verwendet, um beispielsweise ähnliche Datenpunkte zu gruppieren (Clustering) oder die Beziehungen zwischen Variablen zu erkennen (Assoziationen). Häufig kommen diese Algorithmen zum Einsatz, um Daten zu analysieren, zu verstehen und danach für die Verwendung im überwachten Lernen aufzubereiten.

Anmerkung: Semi-überwachtes Lernen ist eine Kombination aus überwachtem und unüberwachtem Lernen, wobei das Modell sowohl mit gelabelten als auch mit ungelabelten Daten versorgt wird. Diese hybride Variante bietet einen Mehrwert, wenn der Datensatz nicht beschriftet ist und die manuelle Beschriftung des gesamten Datensatzes zu zeit- oder kostenaufwändig ist.

2.3.3.2.3 Reinforcement Learning

Das Prinzip des Reinforcement Learning unterscheidet sich von den Ansätzen des Supervised und Unsupervised Learning grundlegend. Das Modell wird dabei in einem bestimmten Zustand initialisiert, es führt eine Aktion aus, wird für diese Aktion belohnt und entwickelt sich auf Basis dieser Belohnung in einen neuen Zustand und führt die nächste Aktion aus. Mit dem Ziel, diese Belohnung zu maximieren, entwickelt es sich nach jeder Handlung in einen neuen Zustand. In einem iterativen Prozess versucht das Modell eine Strategie zu entwickeln, um eine möglichst große Belohnung zu erhalten.

Das eigentliche Training wird lediglich dazu verwendet, das Modell zu initialisieren oder die Richtlinien zu bestimmen, die das Modell bei der Durchführung der Aktionen verwendet.

Reinforcement Learning setzt dabei den Ansatz des Agentenparadigmas um, bei dem das Ziel die Entwicklung eines künstlichen Agenten mit rationalem Verhalten ist, der mit der Umwelt interagiert. Meistens werden die Aktionen des Agenten und Interaktionen mit der Umwelt als Markow-Entscheidungsprozess (MEP, engl.: Markow decision process: MDP) modelliert [80].

Das nach dem russischen Mathematiker Andrei Andrejewitsch Markow benannte Modell bietet einen mathematischen Rahmen für die Modellierung von Entscheidungsprozessen in Situationen, in denen die Ergebnisse teilweise unter der Kontrolle des Entscheidungsträgers stehen und teilweise vom Zufall abhängen [82]. Auf den Markow-Entscheidungsprozess wird an dieser Stelle der Arbeit nicht weiter eingegangen, da der Schwerpunkt der Arbeit auf künstlichen neuronalen Netzen liegt, die zum Bereich des Supervised Learning gehören.

²² In der ISO/IEC 23053:2022 (S. 22) wird diese Grafik mit einem zusätzlichen output (Labels) dargestellt. Auf die Darstellung der Labels als Output wird verzichtet, weil diese an sich kein Ergebnis des Lernprozesses sind.

In der Abbildung 32 ist ein typischer Prozess des Reinforcement Learning dargestellt. Der Agent (bzw. das Modell) führt eine Aktion in der Umwelt aus und bekommt dabei ein Feedback sowie eine Belohnung. Der Agent hat keinen Speicher für Erfahrungen und leitet seine nächste Aktion ausschließlich auf Basis der Beobachtung und der Bewertung ab. Die Belohnung ist meist ein berechneter numerischer Wert, der abbildet, wie nahe der ausgeführten Aktion an einem definierten Ziel liegt. Nach jeder Belohnung geht der Agent in den nächsten Zustand über. Der Zustand bezieht sich auf den Zustand der Umgebung nach der letzten Aktion. Ein beispielhaftes Szenario wäre z.B. beim Schachspiel die Stellung der einzelnen Figuren.

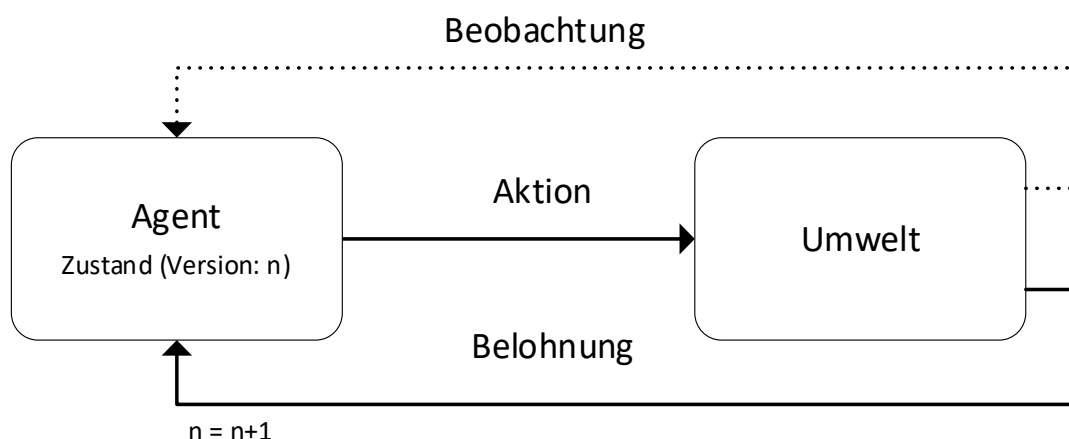


Abbildung 32: Typischer Reinforcement Learning Prozess (Quelle: eigene Darstellung nach [80] S. 24)

2.3.3.3 Datenaufbereitung

Eine zwingende Voraussetzung für die Entwicklung eines qualitativ hochwertigen ML-Modells ist eine qualitativ hochwertige Datengrundlage. Die Abgrenzung der Hochwertigkeit einer Datengrundlage ist zu diesem Zeitpunkt im Prozess aber sehr schwierig. Es gibt keine allgemeingültige Definition, wann eine Datenbasis als qualitativ hochwertig bezeichnet werden kann. Dies hängt unter anderem von dem spezifischen Anwendungsfall sowie von den erwarteten Ergebnissen ab. Ungenauigkeiten während des Trainings des Modells (vgl. Kapitel 2.3.3.6) können auf ein nicht optimiertes Modell hinweisen, aber auch auf eine unzureichende Qualität der Datengrundlage. Während des Trainings gilt es daher, die Qualität der Datengrundlage kontinuierlich auf den Prüfstand zu stellen.

In den seltensten Fällen können die Daten aufgrund ihrer unzureichenden Qualität ohne Aufbereitung für das Training von ML-Modellen verwendet werden.

Die Datenaufbereitung nimmt in der Regel einen erheblichen Teil der Zeit und des Aufwands der Entwicklung eines ML-Modells in Anspruch [80]. Die Datenaufbereitung umfasst neben der Formatierung der Daten eine Vielzahl unterschiedlicher Methoden, um die Qualität des Datensatzes zu optimieren und die Daten bestmöglich an die Anforderungen für das Training von ML-Modellen anzupassen.

Die Datenaufbereitung nach ISO/IEC 23053 [80] kann als eine Art Quality Gate angesehen werden, um eine qualitativ hochwertige Datenbasis zu gewährleisten.

Nachfolgend werden einige dieser Methoden aufgeführt und kurz erläutert. Für eine Gewährleistung einer Vollständigkeit der wesentlichen Verfahren wird auf die Struktur sowie Begrifflichkeiten des Kapitels 8.3 der ISO/IEC 23053 [80] (S. 27 ff.) zurückgegriffen.

- **Exploring**

(dt.: Erkunden)

Bei der Exploration werden die Rohdaten mit verschiedenen Methoden untersucht. Neben der grafischen Darstellung wird versucht mit diversen statistischen Analysemethoden Erkenntnisse über die vorliegenden Daten zu gewinnen. Dazu zählen neben Verteilungsanalysen zum Identifizieren von beispielsweise Ausreißern auch das Bestimmen von Mittelwerten und Standardabweichungen. Die dabei gewonnenen Erkenntnisse können als Anhaltspunkt dienen, welche Maßnahmen für eine Datenaufbereitung am geeignet wären [80].

- **Data wrangling**

(dt.: Datenverarbeitung)

Die Datenverarbeitung hat zum Ziel, die Struktur und Ordnung der vorliegenden Daten zu optimieren. Das kann beispielsweise durch das Zusammenführen, Ergänzen oder Bearbeiten von Spalten oder Datentypen erreicht werden [80].

- **Cleaning**

(dt.: Bereinigen)

Typische Datenbereinigungsverfahren sind die Entfernung von Dubletten, die Ergänzung fehlender Daten (siehe Imputation) und die Behandlung von fehlerhaften Daten sowie Ausreißern [80].

- **Imputation**

(dt.: Imputation)

Bei der Datenimputation werden fehlende Werte durch künstlich erzeugte Werte, wie beispielsweise Mittelwerte, substituiert [80].

- **Normalisation and scaling**

(dt.: Normalisierung und Skalierung)

Ziel der Skalierung ist es, die Werte numerischer Spalten im Datensatz so zu ändern, dass sie in eine bestimmte Skala passen, wie 0 – 1 oder 0 – 100. Die Form der Verteilung bleibt bei der Skalierung erhalten, lediglich die Bereiche werden angepasst. Dadurch können Variablen, die ursprünglich unterschiedliche Skalen hatte, verglichen werden [83, 84].




Abbildung 33: Beispiel für skalierte Daten (Quelle: [84] S. 1)

Beispiele für Skalierungs-Verfahren:

- Simple Feature Scaling,
- Min-Max Scaling.

Im Gegensatz dazu wird bei der Normalisierung die Form verändert, die Daten werden in eine Normalverteilung transformiert [83, 84].




Abbildung 34: Beispiel für normalisierte Daten (Quelle: [84] S. 1)

Beispiele für Normalisierungs-Verfahren:

- Z-Score,
- Box-Cox Normalisation.

Anmerkungen: Normalisierung wird in der Literatur manchmal auch als Standardisierung bzw. Standardisierung als eine spezielle Form der Normalisierung bezeichnet. Beispielsweise verwendet der im maschinellen Lernen häufig verwendete StandardScaler die Formel der Z-Transformation (= Z-Score), eine Technik aus der Normalisierung, um die Daten zu standardisieren. Dabei werden die Daten auf eine standardisierte Skala gebracht und der Wertebereich der Daten normalisiert. Auch in der ISO/IEC 23053 ist der Unterschied zwischen der Normalisierung Skalierung [80] (S. 27 f.) nicht eindeutig erläutert.

- **Dataset composition**

(dt.: Zusammenstellung von Datensätzen)

Die Datenzusammenstellung beschreibt den Prozess, bei dem Daten aus verschiedenen Datenquellen zu einem einzigen Datensatz zusammengeführt werden [80].

- **Dataset splitting**

(dt.: Aufteilung von Daten)

Aufteilung der Daten in drei verschiedene Datensätze [80]:

- Trainingsdaten,
- Testdaten,
- Validierungsdaten.

Der Trainingsdatensatz wird zum Trainieren des Modells verwendet, der Validierungsdatensatz zum Abstimmen der Hyperparameter und der Testdatensatz zur Bewertung der endgültigen Modellleistung. Die Aufteilung orientiert sich dabei immer grob an dem Verhältnis: 80 % Trainingsdaten, 10 % Testdaten und 10 % Validierungsdaten. Die optimale Verteilung ist dabei aber von vielen Faktoren, wie der Struktur des Modells, der Datendimension oder dem Anwendungsfall abhängig [85].

- **Labeling**

(dt.: Kennzeichnen oder Beschriften)

Labeling ist der Prozess, bei dem Eingabedaten (engl.: Features) mit den entsprechend korrekten Ausgabedaten (engl.: Labels) verknüpft werden. Bei einem Modell, das auf Bildern erkennen soll, ob es sich um einen Hund oder eine Katze handelt, wären die Features die zu identifizierenden Bilder und die Labels die Zuordnung „Hund“ bzw. „Katze“ (vgl. Abbildung 35). Die Problemstellung, die durch die KI hier gelöst werden soll, wird als Bilderkennung bezeichnet (vgl. Kapitel 2.3.2.3) [80].

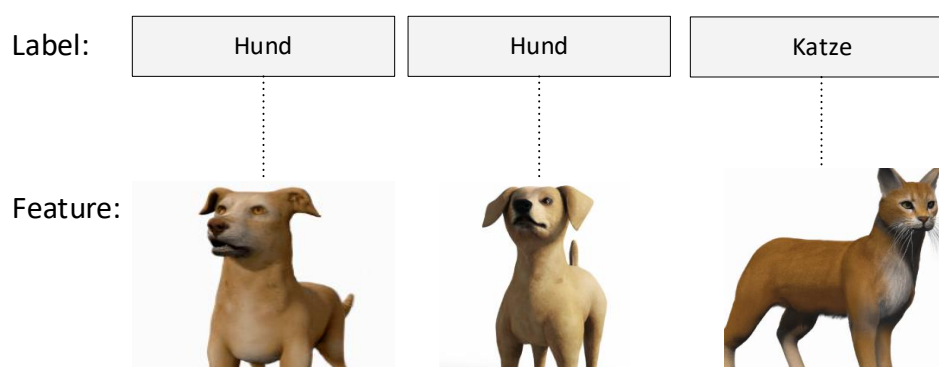


Abbildung 35: Abstrahiertes Beispiel für labeled Data (Quelle: Erstellt durch die KI DALL-E 2)

Ein gelabelter Datensatz enthält dementsprechend die korrekte Zuordnung der Begriffe zu den Bildern, sodass der Algorithmus Muster auf Basis der korrekten Zuordnungen lernen kann. Der dem Modell übergebene Datensatz entspricht gewöhnlich einer tabellarischen Form, in der die Zuordnung zwischen Label und dem Speicherort des

Bildes hergestellt wird. Eine exemplarische Darstellung für das Beispiel „Hund und Katze“ ist in der Tabelle 1 dargestellt.

Tabelle 1: Beispiel für eine Zuordnung zwischen Feature und Label (Computer Vision)
(Quelle: eigene Darstellung)

| Feature | Label |
|----------------|---------|
| \\.\Bild_1.jpg | „Hund“ |
| \\.\Bild_2.jpg | „Hund“ |
| \\.\Bild_3.jpg | „Katze“ |
| \\.\Bild_1.jpg | „Hund“ |
| ... | ... |

Labels können entweder im Originaldatensatz enthalten sein oder manuell hinzugefügt werden. Es ist auch möglich, die Labels durch einen anderen AI-Prozess zu erzeugen. In Abhängigkeit von der jeweiligen Fragestellung können die Labels in den unterschiedlichsten Formen übergeben werden [80]:

- Kategorien bei Klassifikationsproblemen,
- Numerische Werte bei Regressionsproblemen,
- usw.

Regressionsprobleme zeichnen sich dadurch aus, dass für gewöhnlich eine Vielzahl von Features übergeben werden und das Label eine rationale Zahl ist. Ein Beispiel ist in Tabelle 2 dargestellt.

Tabelle 2: Beispiel für die Zuordnung zwischen Features und einem Label (Regression)
(Quelle: Eigen Darstellung)

| Feature_1 | Feature_2 | Feature_3 | ... | Label |
|-----------|-----------|-----------|-----|-------|
| 66111 | 0 | 12.5 | ... | 2.5 |
| 66459 | 0 | 10.5 | ... | 2.3 |
| 67663 | 1 | 12.5 | ... | 1.9 |
| 66459 | 0 | 9.5 | ... | 2.4 |
| ... | ... | ... | ... | ... |

Das Lernen mit bereits gelabelten Daten wird als Supervised Learning (dt.: Überwachtes Lernen) bezeichnet. Weitere Informationen zu dem Ansatz des Supervised Learning befinden sich in Kapitel 2.3.3.2.

2.3.3.4 Künstliche Neuronale Netze

Künstliche Neuronale Netze (KNN; engl.: Artificial Neural Networks, ANN), welche aus einer Reihe von künstlichen Neuronen²³ bestehen, sind die wohl prominenteste Kategorie maschineller Lernalgorithmen.

Die Anfänge der Entwicklung von ANNs geht auf die 1940er Jahre zurück, als die ersten Konzepte von künstlichen Neuronen entstanden. Ein Meilenstein repräsentiert dabei das von Warren McCulloch und Walter Pitts [20] im Jahr 1943 vorgestellte Neuronenmodell McCulloch-Pitts-Zelle bzw. McCulloch-Pitts-Neuron. Dieses mathematische Modell (künstliche Neuron), das die beiden Wissenschaftler entwickelt hatten, war den Nervenzellen (Neuronen) im menschlichen Gehirn nachempfunden und sollte erklären, wie diese funktionieren.

Zum Vergleich ist die menschliche Nervenzelle in der Abbildung 36 dargestellt.




Abbildung 36: Aufbau einer menschlichen Nervenzelle (Neuron) (Quelle: eigene Darstellung nach [86–88])

Über die Dendriten empfangen menschliche Nervenzellen Signale von anderen Nervenzellen, diese Signale werden verarbeitet und als elektrische Impulse über das Axon weitergeleitet, das Axon gibt diese Signale über Kontaktstellen, die Synapsen, an andere Nervenzellen weiter [86, 88].

Basierend darauf entwickelten McCulloch und Walter Pitts ihre künstliche Zelle.

Eine aufgearbeitete Darstellung der McCulloch-Pitts-Zelle aus der Dissertation von Marvin Minsky (1954) [89] kann der Abbildung 37 entnommen werden. Die Eingänge x_1, \dots, x_i repräsentieren die Dendriten, die verarbeitende Funktion in der McCulloch-Pitts-Zelle ist dem Axon nachempfunden.

²³ Der Begriff künstliches Neuron wird im Verlauf dieses Kapitels erläutert.




Abbildung 37: Diagramm einer McCulloch-Pitts-Zelle nach Minsky (Quelle: eigene Darstellung nach [89] S. 2-66)

Basierend auf diesem Modell entwickelte Frank Rosenblatt [90] in den 1950er und 1960er Jahren das Perzeptron. In seiner ursprünglichen Form besteht das Perzeptron nur aus einem einzigen (künstlichen) Neuron, dem sogenannten einfachen Perzeptron.

Inzwischen haben sich aber viele weitere, auch komplexere Modelle etabliert, bei denen mehrerer dieser einfachen Perzeptron-Neuronen zu einem Netz zusammengeschlossen werden [91].

Analog zu den Nervenzellen im menschlichen Gehirn ist die Ausgabe gleichzeitig die Eingabe für das nächste Neuron.

Typischerweise sind diese Neuronen in Schichten (engl.: Layer) angeordnet und innerhalb einer Schicht nicht miteinander, sondern nur mit den Neuronen der nächsten Schicht verbunden.

Ein solcher Verbund der Neuronen in einem Perzeptron wird als Feedforward Neural Network bezeichnet [92].

Weitere Erläuterungen dazu folgen in diesem Kapitel.

Bei der Verwendung der Begrifflichkeiten gibt es in der Literatur keine klare Linie. Otte [91] differenzierte im Jahr 2009 beispielsweise in einer Veröffentlichung zwischen dem einfachen Perzeptron und den mehrschichtigen Perzeptronen mit verschiedenen Aktivierungsfunktionen, Ertel [57] hingegen definierte 2021 das Perzeptron strikt als Äquivalent „zu einem zweilagigen gerichteten neuronalen Netzwerk mit Aktivierung durch eine Schwellwertfunktion [...]“ [11] (S. 212).

Ein ähnlich inhomogenes Bild ergibt sich bei den Ansätzen und den Strukturen des thematisch auf dem Perzeptron aufbauenden Kapitel der ANN.

So schreibt Görz et al. [93] (S. 84), dass sich das mathematische Modell eines KNN in die drei Elemente **Netzwerktopologie** (Art, Anzahl und Anordnung der Elemente), **Gewichte** (Stärke der Beziehungen zwischen den Elementen) und die **Übertragungsfunktion** (Aktivierung der Elemente) unterteilen lässt [93].

Zell [94], ein häufig zitierter Autor auf dem Gebiet der künstlichen Neuronen, weist darauf hin, dass er sich bei seiner Strukturierung an der als "mittlerweile klassisch" bezeichneten Gliederung nach Rumelhart [95] orientiert [94] (S. 72).

In dieser wird differenziert zwischen **Zellen** (Neuronen, Elemente), **Verbindungsnetzwerk**, **Propagierungsfunktion** und der **Lernregel** [94] (S. 72).

Auch bei den Begrifflichkeiten findet man eine Vielzahl von Synonymen oder sich teilweise widersprechende Aussagen, deswegen werden an den entsprechenden Stellen in diesem Kapitel Definitionen festgelegt, die als solche markiert sind.

Definition 3 Für diese Arbeit werden ausschließlich zweischichtige neuronale Netzwerke mit der Aktivierung durch eine Schwellenfunktion als Perzeptron bezeichnet.

Die Definition 3 wurde gewählt, um die gemeinsame Schnittmenge zwischen einem zweischichtigen Neuron und einem Perzeptron möglichst klein zu halten und damit zu einer klaren Abgrenzung beizutragen.

Die für diese Arbeit gewählte Struktur orientiert sich in großen Teilen an der von Zell bezeichneten klassischen Gliederung nach Rumelhart [95].

I. Aufbau einer Zelle (Neuron)

Das Modell eines Neurons mit dem Index j , welches in der Abbildung 38 dargestellt ist, verfügt über i Eingänge $x_1, \dots, x_i \in \mathbb{R}$ bzw. $o_1, \dots, o_i \in \mathbb{R}$, mit den jeweiligen Gewichten $w_{1j}, \dots, w_{ij} \in \mathbb{R}$, dem Schwellenwert θ_j und der Ausgabe $o_j \in \mathbb{R}$.

In der Literatur werden die Eingänge x auch manchmal mit anderen Variablen dargestellt. Braun [96] benutzt beispielsweise die Variable s für die Eingänge, abgeleitet vom Begriff Synapse. Zell [94] hingegen benutzt die Variable o (engl.: Output), begründet damit, dass die Eingänge die Ausgaben anderer Neuronen sind. Für alle Zellen, die sich nicht in der ersten Schicht befinden, sind die Eingaben ausschließlich Ausgaben der Vorgängerzelle i . Deswegen wird in der Anlehnung an die Notation von Zell im weiteren Verlauf die Eingabe mit der Ausgabe der Vorgängerzelle gleichgesetzt.

„Entsprechend dem biologischen Vorbild besitzt ein Neuron mehrere Eingänge (biologisch: Synapsen, die Kontaktstellen des Neurons an seinem Dendritenbaum) eine Ausgabe (biologisch: Axon).“ [96] (S. 7) (vgl. Abbildung 36).

Die Bestandteile einer Zelle werden nach Zell [94] folgendermaßen untergliedert [94] (S. 72):

Aktivierungszustand $a_j(t)$: Grad der Aktivierung der Zelle,

Aktivierungsfunktion f_{act} : Für die Berechnung des neuen Aktivierungszustandes $a_j(t)$ des Neurons j mit der alten Aktivierung $a_j(t - 1)$, der Netzeingabe $net_j(t)$ und dem Schwellenwert θ_j ,

Ausgabefunktion f_{out} : Bestimmung der o_j durch die Anwendung der Ausgabefunktion.




Abbildung 38: Vereinfachte Darstellung eines Neurons (Quelle: eigene Darstellung)

Eingabefunktion²⁴

Im ersten Schritt wird, wie in der Abbildung 38 grafisch illustriert, in der Eingabefunktion mit den Ausgaben der Vorgängerneuronen und den Verbindungsgewichten die so genannte Netzeingabe net_j der Zelle j berechnet [94].

Dafür gilt nach Zell [94] mathematisch folgende Formel (2.2):

$$net_j(t) = \sum_i o_i(t) w_{ij} \tag{2.2}$$

(Quelle: [94] S. 72)

In aktueller Literatur wie bei Ertel [57] von 2021 oder Strecker aus dem Jahr 2004 ist die Eingabefunktion folgendermaßen formuliert (vgl. 2.3):

²⁴ Übertragungsfunktion \triangleq Eingabefunktion \triangleq Eingangsfunktion \triangleq Propagierungsfunktion \triangleq Propagierungsregel.

In dieser Arbeit wird der Begriff der Eingangsfunktion verwendet. Für weitere Erläuterungen siehe „Anmerkung“ am Ende des Abschnittes „Eingabefunktion“.

$$net_j = \sum_{i=1}^n x_i w_{ij} \quad 2.3$$

(Quelle: [57] S. 215, [97] S. 28)

Auf den meisten seriösen Internetquellen wird auf die (deutsche) Version von Wikipedia (vgl. 2.4, 2.5, dabei gilt $2.4 \equiv 2.5$) zurückgegriffen, für die dort keine Quelle hinterlegt ist.

Bei Wikipedia (deutsch) heißt es dazu „die Aktivierung v (in der Abbildung oben als "Netzeingabe" oder "net" bezeichnet)“ [98], die Gleichsetzung von Aktivierung und der Netzeingabe ist aber von der Terminologie falsch!

Der griechischen Buchstaben v (Ypsilon) steht hier für die Netzeingabe, nicht für die Aktivierung. Denn der Zusammenhang zwischen a_j und net_j ist folgendermaßen: $a_j = f_{act}(net_j)$ [97] (S. 32), daher ist v die Netzeingabe.

Für die Aktivierungsfunktion wird im Internet für Gewöhnlich der griechische Buchstabe φ (Phi) benutzt, daher gilt außerdem: $f_{act}(net_j) \equiv \varphi(v)$.

$$v = \sum_{i=1}^n x_i w_{ij} + w_0 \quad 2.4$$

$$v = \sum_{i=0}^n x_i w_{ij} \quad 2.5$$

(Quelle: [98] abgerufen am 11.02.2023)

Die Differenzen zwischen den Formeln 2.4, 2.5 im Vergleich zur Formel 2.3 bzw. 2.2 sind damit zu begründen, dass die optionalen Bias-Neuronen an unterschiedlichen Stellen berücksichtigt werden, daher gibt es keinen Widerspruch zwischen den Formeln. Weitere Informationen dazu folgen bei der Erläuterung des Bias-Neurons.

Für die Zwecke dieser Arbeit wird festgestellt, dass die Darstellung der Netzberechnung durch die Formeln 2.4 bzw. 2.5 am leichtesten verständlich ist und daher die Verwendung dieser Formeln für die Netzberechnung empfohlen wird, mit der Festlegung, dass v die Netzeingabe ist.

Anmerkung: In der Literatur findet sich eine Vielzahl von weiteren Varianten der Eingangsfunktionen wie beispielsweise die von Braun [96], mit Abbildung des Schwellenwertes θ , welche bei Netzen mit Schwellenwerten eingesetzt werden. Für die Anwendung der Formel (2.7) von Braun bei einem Netz ohne Schwellenwert, kann die Schwelle $\theta_i = 0$ gesetzt werden bzw. bei der Verwendung eines Bias-Neurons gilt (2.6):

$$b_i \triangleq -\theta_i \quad 2.6$$

$$net_i := \sum_j w_{ij}s_j - \theta_i \quad 2.7$$

(Quelle: [96] S.8)

Anmerkung: Bereits Crone [99] merkt in seiner Literatur an, dass die Verarbeitungsfunktionen in der Literatur unterschiedlich benannt und kombiniert werden [99] (S. 175 ff.). Als Beispiel nennt Crone die „[...] Zusammenfassung der Aktivierungs- und der Ausgabefunktion, der Eingabe- und der Aktivierungsfunktion oder gar der Kombination aller Verarbeitungsfunktionen zu einer allgemeinen Transferfunktion.“ [99] (S. 175 f.) Als Quellen für seine Aussage nennt er [94] (S. 89), [95] und [100] (S. 88).

Zell [94] schreibt außerdem, dass einige Autoren fordern, dass man nichtlineare „Ausgabefunktionen“ oder „Transferfunktionen“ an der Stelle einer „Aktivierungsfunktion“ verwenden soll [94] (S. 76). „Grundsätzlich erfolgt eine Verarbeitung jedoch in den elementaren Schritten Eingabe, Berechnung der Aktivierung und Kodierung der Ausgabe, weshalb die einzelnen Berechnungen als disjunkte Verarbeitungsfunktionen abgebildet werden.“ [99] (S. 176).

Aktivierungsfunktion

Über die in der Eingabefunktion berechnete Netzeingabe net_i kann der Aktivierungszustand $a_j(t)$ mit der Hilfe der Aktivierungsfunktion f_{act} bzw. φ ($f_{act} \equiv \varphi$) berechnet werden, welcher den Grad der Aktivierung der Zelle j angibt.

$$a_j(t) = f_{act}(a_j(t-1), net_j(t), \theta_j) \quad 2.8$$

(Quelle: Modifizierte Formel nach [94] S. 72)

$$a_j(t+1) = f_{act}(a_j(t), net_j(t), \theta_j) \quad 2.9$$

(Quelle: Originalformel nach [94] S. 72)

In der Originalformel von Zell [94] werden für die Berechnung der neuen Aktivierung $a_j(t+1)$ der Aktivierungsfunktion f_{act} die alte Aktivierung $a_j(t)$, die Netzeingabe $net_j(t)$ und der Schwellenwert θ_j übergeben. Zur Vermeidung des Missverständnisses, dass hierbei die alte Aktivierung $a_j(t)$ benutzt wird, aber die aktuelle Netzeingabe $net_j(t)$, wurde die originale Formel (2.9) an dieser Stelle modifiziert (2.8).

Zell schreibt bezüglich der alten Aktivierung $a_j(t)$ Folgendes: „In vielen Fällen haben die Zellen kein ‚Gedächtnis‘, d.h. die neue Aktivierung $a_j(t + 1)$ ist nicht abhängig von der alten Aktivierung [...]“ [94] (S. 83).

Bezüglich der Übergabe des Schwellenwerts θ_j merkt er als Fußnote an, dass manche Autoren den Schwellenwert mit inversem Vorzeichen implementieren [94] (S. 81). Außerdem müsse man bei einem Netz ohne Schwelle, aber mit einem „on“-Neuron bei seiner Formel das „on“-Neuron mit einem Gewicht von -1 als Schwellenwert θ_j verwenden [94] (S. 82). Das entspricht der Festlegung von Braun (vgl. 2.6).

Hinsichtlich der Aktivierung gibt es nach Sonnet [97] (S. 29 ff.) vier übliche Methoden, diese können der Tabelle 3 entnommen werden. Die Wahl der Aktivierungsmethode steht in Abhängigkeit des zu lösenden Problems und dessen Randbedingungen.

Allgemein kann man aber sagen, dass lineare Aktivierungsfunktionen nicht bei Netzwerken mit mehreren Schichten eingesetzt werden [94] (S. 89).

Tabelle 3: Übliche Methoden der Aktivierung nach Sonnet (Quelle: eigene Darstellung nach [97])

| | |
|------|---|
| I. | Aktivierung entspricht der Netzeingabe |
| II. | Schwellenwertfunktion als Aktivierungsfunktion |
| III. | Fermi-Funktion oder Tangens hyperbolicus als Aktivierungsfunktion |
| IV. | Rectified Linear Unit als Aktivierungsfunktion |

Nähere Erläuterungen zu den Methoden der Tabelle 3 folgen.

I. Aktivierung entspricht der Netzeingabe

Keine Verwendung einer Aktivierungsfunktion (vgl. 2.10). Die Netzeingabe entspricht somit der Aktivierung.

$$f_{act}(net_j) = net_j \quad 2.10$$

[97] (S. 29)

Nach Zell [94] handelt es sich bei dieser Funktion um die Identitätsfunktion f_{ident} [94] (S. 77). Eine Skizze der grafischen Darstellung der Funktion findet sich in der Abbildung 39. Dabei entspricht die X-Achse der Netzeingabe net_j und die Y-Achse dem Ergebnis der Aktivierungsfunktion f_{act} .




Abbildung 39: Skizze der Identitätsfunktion (Quelle: eigene Darstellung)

II. Schwellenwertfunktion als Aktivierungsfunktion

Als Aktivierungsfunktion wird eine Schwellenwertfunktion eingesetzt (vgl. 2.11).

$$f_{act}(net_j) = \begin{cases} 0, & net_j < \theta \\ 1, & net_j \geq \theta \end{cases} \quad 2.11$$

(Quelle: [97] S. 30)

Für den Schwellenwert $\theta = 0$ würde die Funktion 2.11 folgendermaßen aussehen (vgl. 2.12):

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad 2.12$$

Eine grafische Darstellung der Funktion zeigt Abbildung 40. Dabei entspricht die X-Achse der Netzeingabe net_j und die Y-Achse dem Ergebnis der Aktivierungsfunktion f_{act} .




Abbildung 40: Skizze der Schwellenwertfunktion mit der Schwelle $\theta = 0$ (Quelle: eigene Darstellung)

Der Schwellenwert stellt damit die Grenze da, ab der ein Neuron aktiviert wird. Das Neuron ist für alle Werte $x < 0$ inaktiv (Neuron ruht) und bei Werten $x \geq 0$ wechselt es in den aktiven Zustand (Neuron feuert).

In einem theoretischen Beispiel unter den nachstehenden Annahmen würde sich der Wert für die Ausgabe o folgendermaßen berechnen:

Eingangswerten: $x_1 = 1$, $x_2 = 0$, $x_3 = 1$

Gewichte: $w_1 = 0.4$, $w_2 = 0.1$, $w_3 = -0.3$

Aktivierungsfunktion $\varphi: f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$

Schwellenwert $\theta: 0$

$$net_j = x_1 w_1 + x_2 w_2 + x_3 w_3 - 0$$

$$net_j = 0.4 + 0 + (-0.3) - 0$$

$$net_j = 0.1$$

$$a_j = f_{act}(0.1)$$

$$a_j = 1$$

$$o = 1 \text{ (unter der Annahme, dass } a_j = f_{out}(a_j))^{25}$$




Abbildung 41: Beispiel mit Werten eines Perzeptrons (zweischichtiges Neuron mit Schwellenwertfunktion) (Quelle: eigene Darstellung)

Das in der Abbildung 41 dargestellte Neuron würde damit in den aktiven Zustand wechseln (Neuron feuert).

Die Schwellenwertfunktion ist, wie bereits erwähnt, nur eine von vielen möglichen Aktivierungsfunktionen. Bedingt dadurch, dass die Schwellenwertfunktion an ihrer Sprungstelle nicht differenzierbar ist, findet sie ausschließlich in sehr einfachen Modellen Anwendung. Die Differenzierbarkeit ist eine Voraussetzung für den Erfolg des Lernalgorithmus bei mehrschichten

²⁵ Die Erläuterung der Ausgabefunktion folgt im weiteren Verlauf des Kapitels.

Netzen, deswegen wird bei mehrschichtigen Netzen oft auf die Sigmoid-Funktion bzw. Fermi-Funktion zurückgegriffen [91].

III. Fermi-Funktion oder Tangens hyperbolicus als Aktivierungsfunktion

Die Fermifunktion (logistische Funktion) gehört wie die der Tangens hyperbolicus zu den Sigmoidfunktionen. Oft wird der Begriff der Sigmoidfunktion auf die logistische Funktion bezogen, tatsächlich repräsentiert die Sigmoidfunktion aber eine Menge von Funktionen mit einem S-förmigen Graphen.

Eine Skizze der grafischen Darstellung der logistischen Funktion (Formel 2.13) erklärt Abbildung 42. Dabei entspricht die X-Achse der Netzeingabe net_j und die Y-Achse dem Ergebnis der Aktivierungsfunktion f_{act} .

$$\text{sig}(x) = \frac{1}{1 + e^{-x}} \quad 2.13$$




Abbildung 42: Skizze der logistischen Funktion (Quelle: eigene Darstellung)

Sigmoidfunktionen kommen vor allem wegen ihrer Differenzierbarkeit in Neuronalen Netzwerken oft zum Einsatz.

IV. Rectified Linear Unit als Aktivierungsfunktion

Die gleichgerichtete lineare (engl.: rectified linear) Aktivierungsfunktion (Abkürzung: ReLU) ist eine teilweise lineare Funktion, die die Eingabe direkt ausgibt, wenn sie positiv ist, andernfalls gibt sie Null aus.

Mathematisch wird die ReLU folgendermaßen formuliert:

$$f(x) = \max(0, x) \quad 2.14$$

Eine grafische Darstellung der logistischen Funktion zeigt Abbildung 32. Dabei entspricht die X-Achse der Netzeingabe net_j und die Y-Achse dem Ergebnis der Aktivierungsfunktion f_{act} .




Abbildung 43: Skizze der ReLU-Aktivierungsfunktion (Quelle: eigene Darstellung)

Auf die konkreten Unterschiede zwischen der ReLU-Funktion und der Sigmoidfunktion wird aufgrund des Schwerpunkts der Arbeit nicht weiter eingegangen.

Ausgabefunktion

Die letztendliche Ausgabe o_j ergibt sich aus der Anwendung der Ausgabefunktion f_{out} auf die errechnete Aktivierung a_j nach der mathematischen Formulierung 2.15.

$$o_j = f_{out}(a_j) \quad 2.15$$

(Quelle: [94] S. 72)

Sie ermöglicht die Kodierung der Ausgabe o_j durch Skalierung der Aktivierung a_j in ein abweichendes Intervall [99] (S. 175). Cron schreibt weiter, dass diese Skalierung bei Klassifikationsaufgaben zum Einsatz kommt und beispielsweise bei Regressionsproblemen nicht relevant ist [99] (S. 175). Schumann et al. [101] schreiben dazu allgemein, dass die Ausgabefunktion in den meisten Netzwerkmodellen ohne Funktion ist und den Eingabewert unverändert ausgibt [101] (S. 25).

Die Funktion, welche jeder reellen Zahl wieder genau die identische reelle Zahl zuordnet, wird als Identität auf \mathbb{R} bezeichnet, deswegen wird die Formulierung 2.15. auch folgendermaßen dargestellt:

$$o_j = f_{ident}(a_j) = a_j \quad 2.16$$

(Quelle: [99] S. 175)

Bei Ausgabefunktionen f_{out} wird auf die gleichen Funktionen wie bei der Aktivierungsfunktion f_{act} zurückgegriffen (vgl. Überblick in der Tabelle 3).

Verbindungsnetzwerk der Zellen

Nach Zell kann ein neuronales Netzwerk auch als gerichteter gewichteter Graph gesehen werden, dabei repräsentieren die Kanten die gewichteten Verbindungen zwischen den Neuronen [94] (S. 72).

Das Gewicht der Zelle i zu Zelle j wird als w_{ij} bezeichnet, die Reihenfolge ist dabei wichtig, weil gegensätzliche Konventionen bei der Notation ist [94] (S. 79). Auf die uneinheitliche

Verwendung in der Literatur wird an diese Stelle nicht weiter eingegangen, nähere Erläuterungen dazu befinden sich bei Zell in den Hinweisen zur Matrixschreibweise auf Seite 80 [94].

Die Gewichte sind anfänglich zufallsgeneriert und bestimmen den Grad des Einflusses der Eingaben in der Aktivierungsfunktion [102]. Gewichte mit einem positiven Vorzeichen wirken erregend (exzitatorisch) und Gewichte mit einem negativen Vorzeichen hemmend (inhibitorisch) [103].

Erst durch das Training in der Form des Supervised Learning, des Unsupervised Learning oder des Reinforcement Learning werden die Gewichte festgelegt und die mathematische Funktion erstellt, die den Zusammenhang zwischen der Eingabe und der Ausgabe abbildet [94, 103]. Falls notwendig, wird die Netzwerktopologie dabei iterativ angepasst [102]. Das Modell sowie die Gewichte können nach dem Training abgespeichert und wieder geladen werden.

Bias-Neuron

Auch bei der Verwendung der Begriffe Bias²⁶ und Schwellenwert unterscheiden sich die Ansätze in der Literatur signifikant. So differenziert Zell [94] zwischen dem Schwellenwert und dem „on“-Neuron, wobei „bias“ für Zell dem Schwellenwert entspricht [94] (S. 81). Ertel [57] und Otte [91] benennen die „on“-Neuronen als Bias-Neuronen [57] (S. 314). Crone [99] schreibt, dass das Bias auch häufig als Threshold oder Schwellenwert bezeichnet wird [99] (S. 172). Zell [94] schreibt dazu als Anmerkung, dass manche Autoren den Schwellenwert mit inversem Vorzeichen abbilden [94] (S. 81), und erläutert dabei, „der Schwellenwert kann unterschiedlich realisiert werden, entweder als Parameter in den Neuronen, der in die Aktivierungsfunktion eingeht, oder über eine Technik mit Gewichten und einem sogenannten ‚on‘-Neuron.“ [94] (S. 81).

Aufgrund dieser unklaren Linie wird für diese Arbeit definiert:

Definition 4

Bias-Neuron \triangleq „on“-Neuron.

Schwellenwert \triangleq (engl.) Threshold.

Verzerrung \triangleq (engl.) Bias.

Für das Verhältnis zwischen dem Bias-Neuron b_i und dem Schwellenwert θ gilt: $b_i \triangleq -\theta_i$.

Ein Bias-Neuron ist ein zusätzliches optionales Neuron, welches immer mit dem konstanten Eingang $x_0 = +1$ (als erstes Neuron) bzw. $x_{n+1} = +1$ (als letztes Neuron) initialisiert wird.

Grundsätzlich fungiert das Bias als dynamischer Schwellenwert und kann die Ausgabe o positiv beeinflussen [92]. In der Formel 2.3 wird das Bias als letztes Neuron berücksichtigt. Zur Konkretisierung mögen die Abbildung 44 und Abbildung 45 dienen.

²⁶ Der Begriff "Bias" bezieht sich auf systematische Fehler oder Verzerrungen, die bei einer Erhebung, einer Analyse oder einer Interpretation von Daten auftreten können.

Bei n Eingängen wird das Bias dementsprechend bei x_{n+1} mit dem Wert 1 und dem Gewicht $w_{i=n+1,j} = b_i$ initialisiert.




Abbildung 44: Bias-Neuronen Beispiel (letzter Eingang) (Quelle: eigene Darstellung)

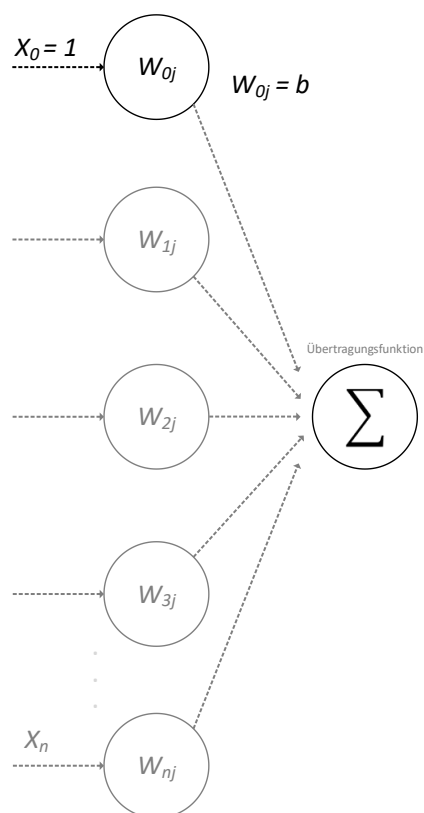


Abbildung 45: Bias-Neuronen Beispiel (erster Eingang) (Quelle: eigene Darstellung)

Wird das Bias-Neuron bei x_0 berücksichtigt, wie in der Abbildung 45 illustriert, kann die mathematische Darstellung auch folgendermaßen aussehen:

$$net_j = \sum_{i=1}^n w_{ij}x_i + w_{0j} = \sum_{i=0}^n w_{ij}x_i \tag{2.17}$$

Schichten

Wie bereits am Anfang des Kapitels angesprochen, sind Neuronen in sogenannten Schichten (engl.: Layer) angeordnet, typischerweise als Feedforward Neural Network²⁷. Dabei werden die Schichten in drei verschiedene Arten unterteilt [91]:

²⁷ neben der vorwärtsgerichtete Informationsverarbeitung (Feedforward) gibt es auch die rückgekoppelte Informationsverarbeitung (Feedbackward) [104]. Aufgrund des Schwerpunktes der Arbeit wird ausschließlich auf Feedforward Netze eingegangen. Weitere Informationen zu Feedbackward Netzen finden man beispielsweise bei Strecker [104] oder Zell [94].

- Eingangsschicht (Input-Layer): keine Neuronen im eigentlichen Sinn, es dient in den meisten Netzen nur als Zwischenspeicher und führen keine Berechnungen aus [104],
- Verdeckte Schicht (Hidden-Layer): Schichten zwischen dem Input-Layer und dem Output-Layer, in denen die Informationsverarbeitungsprozesse stattfinden [104],
- Ausgabeschicht (Output-Layer): Aufbereitung der Netzausgabe, fungiert ebenfalls als Zwischenspeicher wie der Input-Layer [104].

Ein KNN verfügt immer über einen Input-Layer, einen Output-Layer und eine variable Anzahl an Hidden-Layer. Ein Perzeptron, wie in der Abbildung 46 dargestellt, besitzt lediglich einen Input-Layer und einen Output-Layer. Mehrschichtige KNN hingegen über mindestens einen Hidden-Layer.




Abbildung 46: Beispiel für ein einschichtiges Netz (Perzeptron)

(Quelle: eigene Darstellung nach [104] S. 18)




Abbildung 47: Beispiel für ein unvollständig verbundenes zweischichtiges Netz

(Quelle: eigene Darstellung nach [104] S. 18)




Abbildung 48: Beispiel für ein vollständig verbundenes zweischichtiges Netz

(Quelle: eigene Darstellung nach [104] S. 18)

Die Neuronen können unvollständig (Abbildung 47) oder vollständig verbunden (Abbildung 48) sein [104].

Je nach Literatur wird der Input-Layer mitgezählt oder nicht berücksichtigt.

Zell kommentiert diese Begebenheit mit der folgenden Anmerkung „Die Anzahl der Stufen neuronaler Netze wird (wie viele andere Begriffe auch) leider in der Literatur über neuronale Netze nicht einheitlich verwendet.“ [94] (S. 73).

Zell bezeichnet ein Netz als n-stufig, wenn das Netz n-Schichten trainierbarer Verbindungen hat. Ein n-stufiges Netz hat n+1 Schichten von Neuronen, davon n-1 Schichten verdeckte Neuronen und er schlägt den Begriff „Netze mit n Stufen trainierbarer Verbindungen“ vor, um Missverständnisse zu vermeiden [94] (S. 73).

Bei der Definition von Schichten nach Zell [94] wird die Eingangsschicht deswegen nicht mitgezählt, da sie in der Regel nicht trainierbar ist und nur Eingabedaten aufnimmt und diese an

die nächste Schicht weiterleitet. In dieser Arbeit wird sich nach der Konvention von Zell gerichtet.

Daher wird das einfache Perzeptron als einlagig oder einschichtiges Modell bezeichnet [91].

Ergänzung: Der Begriff der Propagation

Die Propagation ist der Prozess, bei dem eine Eingabe durch das ganze Netz, vom Input-Layer bis zum Output-Layer, „hindurch propagiert“ wird [91]. Bei diesem Prozess wird für jedes Neuron, beginnend mit dem Neuron des ersten Hidden-Layers, eine Netzausgabe nach Formel 2.2 berechnet. Diese berechnete Ausgabe dient dabei als Eingabe für die Neuronen der folgenden Schicht. Die Eingabe für die Berechnung der Netzausgabe im Perzeptron resultiert direkt aus dem Input-Layer. Der Prozess der Propagation endet mit der Netzausgabe am Output-Layer des Netzes.

Lernen

Die Lernregel ist der Algorithmus, nach dem das neuronale Netz, für eine Eingabe eine bestimmte Ausgabe erzeugt. Durch die Modifikation bestimmter Elemente im Netz, versucht das Netz seine Ausgabe kontinuierlich der gewünschten Ausgabe anzunähern. Realisiert wird das durch den Versuch, den Fehler zwischen der erwarteten Ausgabe und der tatsächlichen Ausgabe zu minimieren [94] (S. 73).

In der Theorie gibt es viele Möglichkeiten, wie neuronale Netze lernen können. Nach Zell wird das Lernen in sieben verschiedene Arten unterteilt [94] (S. 84):

- i. „Entwicklung neuer Verbindungen,
- ii. Löschen existierender Verbindungen,
- iii. Modifikation der Gewichte,
- iv. Modifikation des Schwellenwertes,
- v. Modifikation der Aktivierungs-, Eingabe- oder Ausgabefunktion,
- vi. Entwicklung neuer Zellen,
- vii. Löschen von bestehenden Zellen.“

Diese Alternativen können einzeln oder in einer Kombination angewendet werden, am häufigste kommt dabei die Modifikation der Gewichte zum Einsatz [94] (S. 84).

Basierend auf diesen Möglichkeiten, ein Netz anzupassen, gibt es viele sogenannte Lernregeln, bei denen mathematisch definiert wird, in welchem Fall über welche Art das Netz angepasst wird.

Hebbsche Lernregel

Die Grundlage für die meisten Lernregeln bildet die Hebbsche Lernregel, welche 1949 von Donald O. Hebb formuliert wurde [94] (S. 84).

Mathematisch formuliert lautet diese:

$$\Delta w_{ij} = \eta o_i a_j \quad 2.18$$

(Quelle: [94] S. 84)

Dabei ist Δw_{ij} die Änderung des Gewichts, η eine Konstante (Lernrate), o_i die Ausgabe der Vorgängerzelle und a_j die Aktivierung der Nachfolgerzelle. Wenn die Zelle j eine Eingabe der Zelle i erhält und beide gleichzeitig stark aktiviert sind, dann erhöht sich das Gewicht w_{ij} – die Verbindung zwischen der Zelle j und der Zelle i [94] (S. 84). Je häufiger ein Neuron j gleichzeitig mit einem Neuron i aktiv ist, desto eher reagieren die beiden Neuronen aufeinander. Diesbezüglich hat sich auch der Satz „What fires together, wires together“ etabliert, welcher in der Originalfassung („Cells that fire together, wire together“) von Donald Hebb stammen soll [105]. Die Hebbsche Lernregel, welche beim Unsupervised Learning eingesetzt wird, bildet die Grundlage für die folgenden Lernregeln.

Delta-Regel

Eine spezialisierte Form der Hebbschen Lernregel ist die sogenannte Delta-Regel, auch Widrow-Hoff-Regel genannt [95], sie wird beim Supervised Learning eingesetzt.

$$\Delta w_{ij} = \eta o_i(t_j - a_j) = \eta o_i \delta \quad 2.19$$

(Quelle: [94] S. 85)

δ (Delta) entspricht dabei der Differenz zwischen der erwarteten Aktivierung t_j (teaching input) und der tatsächlichen Aktivierung a_j , η der Lernrate und o_i der Ausgabe der Vorgängerzelle [94]. In einer weiteren Variante der Delta-Regel (2.20) entspricht δ (Delta) nicht der Differenz der Aktivierung, sondern der Differenz zwischen der erwarteten Ausgabe t_j (teaching input) und der tatsächlichen Ausgabe o_j [94].

$$\Delta w_{ij} = \eta o_i(t_j - o_j) = \eta o_i \delta_j \quad 2.20$$

(Quelle: [94] S. 85)

Beide Formeln sind äquivalent, weil die Deltaregel ausschließlich bei einschichtigen Netzen mit einer linearen Aktivierungsform zum Einsatz kommt. Die verallgemeinerte Form der Delta-Regel für den Einsatz bei mehrschichtigen Netzen mit nichtlinearen Aktivierungsfunktionen wird als Backpropagation-Regel bezeichnet [94] (S. 85).

$$\Delta w_{ij} = \eta o_i \delta_j \quad 2.21$$

[94] (S. 86)

Der Unterschied zur Delta-Regel ist dabei, dass sich δ_j etwas komplizierter berechnet:

$$\delta_j = \begin{cases} f'_{(act)j}(net_j)(t_j - o_j) & \text{falls } j \text{ eine Ausgabezelle ist.} \\ f'_{(act)j}(net_j) \sum_k (\delta_k, w_{jk}) & \text{falls } j \text{ eine verdeckte Zelle ist.} \end{cases} \quad 2.22$$

(Quelle: Modifiziert nach [94] S. 86)

δ_j ist dabei das Fehlersignal des aktuellen Neurons, die Laufvariable k läuft über alle direkt nachfolgenden Zellen. Bei der Backpropagation wird analog zum einschichtigen Netz eine Eingabe durch das Netz propagiert, für jedes Neuron (außer der Inputschicht) wird ein spezifisches Fehlersignal δ_j berechnet, die Gewichtsänderung Δw_{ij} für jedes Gewicht wird berechnet, die neuen Gewichtungen w_{ij}^{neu} werden berechnet. Die neuen Gewichte werden erst dann übernommen, wenn die Propagation abgeschlossen ist, daher werden bei sämtlichen Berechnungen während der Back-Propagation die alten Gewichtungen w_{ij}^{alt} verwendet [91, 106].

Ziel beim Supervised Learning ist die Minimierung des Fehlers des Netzes. Dieser quantifiziert die Abweichung zwischen der erwarteten Netzausgabe und der tatsächlichen Netzausgabe, nachdem eine Eingabe durch das Netz propagiert wurde. Dieser Fehler lässt sich durch sogenannte Abweichungs- oder Fehlerfunktionen berechnen [91], eine klassische Fehlerfunktion ist der quadratische Fehler SSE²⁸ (engl.: Sum of Square) [92, 106].

Weitere Fehlerfunktionen finden Sie in Kapitel 2.3.3.6.

2.3.3.5 Deep Learning

Ein Artificial Neural Network wird als Deep Learning bezeichnet, wenn es über mehrere Schichten verfügt, die miteinander verknüpft sind. Je mehr Schichten ein künstliches neuronales Netz hat, desto tiefer ist es und desto mehr komplexe Funktionen kann es erlernen. Deep-Learning-Modelle werden häufig für komplexe Probleme wie Computer Vision, Spracherkennung und maschinelle Übersetzung verwendet, da sie zum Lernen und Extrahieren hierarchischer Funktionen fähig sind, die für diese Aufgaben relevant sind.

Der Begriff des Deep Learning für die Verwendung mehrschichtiger Netze taucht zum ersten Mal im Jahr 2000 in dem Buch „MultiValued and Universal Binary Neurons: Theory, Learning and Applications“ [107] der Autoren Aizenberg et al. auf. Allerdings wurden bereits vor dem Jahr 2000 mehrschichtige Neuronale Netze trainiert, wie beispielsweise in dem Aufsatz „Backpropagation Applied to Handwritten Zip Code Recognition“ [108] von LeCun et al. aus dem Jahr 1989 dokumentiert ist [97].

²⁸ Neben der SSE gibt es noch viele weitere Fehlerfunktionen. Crone [99] schreibt „Im Gegensatz zu den theoretischen Fähigkeiten von NN zur Minimierung und somit Nutzung unterschiedlicher Zielfunktionen wird seit ihrer populären Beschreibung in der Originalpublikation des Backpropagation-Algorithmus durch RUMELHART, HINTON und WILLIAMS [1986] nahezu ausschließlich die Fehlerfunktion der Summe der quadratischen Fehler SSE verwendet. Sie wird in der wissenschaftlichen Forschung ebenso wie in praktischen Anwendungen universell sowohl zur Regression als auch zur Klassifikation eingesetzt.“ [99] (S. 242).

Eine einheitliche Definition von Deep Learning gibt es nicht, aber allgemein werden alle mehrschichtigen ANN(s) als Deep Learning verstanden.

2.3.3.6 Lernkurve

Die Lernkurve fungiert als visuelle Repräsentation des Verlaufs des Lernprozesses eines maschinellen Algorithmus über die Epochen²⁹ hinweg. Bei Regressionsproblemen wird für gewöhnlich dieser Lernprozess durch die zeitliche Entwicklung des Loss (dt.: Verlust) beim Trainingsdatenset und Validierungsdatenset dargestellt. Der Loss beim Trainingsdatenset wird als Training Loss (dt.: Trainingsverlust) bezeichnet, der Loss beim Validierungsdatenset als Validation Loss (dt.: Validierungsverlust). Eine solche Lernkurve ist in der Abbildung 50 illustriert.

Der sogenannte Loss kann durch verschiedene Metriken quantifiziert werden. Bei Klassifikationsproblemen wird beispielsweise häufig der F1-Score verwendet, um die Leistung des Modells zu bewerten. Bei Regressionsproblemen hingegen wird häufig der Mean Absolute Error (MAE) verwendet, um den mittleren absoluten Fehler zwischen den vorhergesagten Werten und dem Zielwert zu berechnen. Sollen größere Fehler stärker gewichtet werden, das Modell also bei signifikanten Fehlern stärker abgestraft werden, kann man stattdessen den Mean Squared Error (MSE) einsetzen. Dieser gibt den mittleren quadratischen Fehler zwischen dem prognostizierten und dem tatsächlichen Wert an.

Die Wahl der geeigneten Metrik hängt von der Art des Problems und den spezifischen Anforderungen der Anwendung ab.

In der Online-Dokumentation der scikit-learn-Bibliothek (vgl. Kapitel 2.3.3.8) befindet sich eine Auflistung der gebräuchlichsten Metriken bzw. aller in scikit-learn implementierten Metriken mit einer entsprechenden Erläuterung zur Verwendung.

Die relevanten Metriken für die Regression sind in der Abbildung 49 dargestellt.

²⁹ Epochen beschreiben im maschinellen Lernen die Anzahl der Durchläufe des gesamten Datensatzes durch den Algorithmus. Bei den Epochen handelt es sich um einen Hyperparameter, der vor dem Trainingsprozess bestimmt wird.

Regression metrics

See the [Regression metrics](#) section of the user guide for further details.

| | |
|--|--|
| <code>metrics.explained_variance_score(y_true, ...)</code> | Explained variance regression score function. |
| <code>metrics.max_error(y_true, y_pred)</code> | The <code>max_error</code> metric calculates the maximum residual error. |
| <code>metrics.mean_absolute_error(y_true, y_pred, *)</code> | Mean absolute error regression loss. |
| <code>metrics.mean_squared_error(y_true, y_pred, *)</code> | Mean squared error regression loss. |
| <code>metrics.mean_squared_log_error(y_true, y_pred, *)</code> | Mean squared logarithmic error regression loss. |
| <code>metrics.median_absolute_error(y_true, y_pred, *)</code> | Median absolute error regression loss. |
| <code>metrics.mean_absolute_percentage_error(...)</code> | Mean absolute percentage error (MAPE) regression loss. |
| <code>metrics.r2_score(y_true, y_pred, *, [...])</code> | R^2 (coefficient of determination) regression score function. |
| <code>metrics.mean_poisson_deviance(y_true, y_pred, *)</code> | Mean Poisson deviance regression loss. |
| <code>metrics.mean_gamma_deviance(y_true, y_pred, *)</code> | Mean Gamma deviance regression loss. |
| <code>metrics.mean_tweedie_deviance(y_true, y_pred, *)</code> | Mean Tweedie deviance regression loss. |
| <code>metrics.d2_tweedie_score(y_true, y_pred, *)</code> | D^2 regression score function, fraction of Tweedie deviance explained. |
| <code>metrics.mean_pinball_loss(y_true, y_pred, *)</code> | Pinball loss for quantile regression. |
| <code>metrics.d2_pinball_score(y_true, y_pred, *)</code> | D^2 regression score function, fraction of pinball loss explained. |
| <code>metrics.d2_absolute_error_score(y_true, ...)</code> | D^2 regression score function, fraction of absolute error explained. |

Abbildung 49: Screenshot der Dokumentation von scikit-learn (regression metrics) (Quelle: [109])

Die Darstellung der Lernkurve für den Training Loss (grüne Kurve in der Abbildung 50) und den Validation Loss (blaue Kurve in der Abbildung 50), wie in der Abbildung 50 beispielhaft dargestellt, gibt Aufschluss über die Leistungsfähigkeit des Modells mit den Trainingsdaten, d.h., wie gut der iterative Prozess zur Verbesserung der Vorhersagegenauigkeit verläuft. Die Kurve des Validation Loss gibt Aufschluss darüber, wie gut das Modell mit neuen Daten zurechtkommt, die das Modell nicht kennt, d.h., wie gut das Modell generalisieren kann.




Abbildung 50: Trainings and Validation Loss - Kurve (MSE) (Quelle: eigene Darstellung)

Im Beispiel in der Abbildung 50 wurde der MSE als Metrik verwendet. Je kleiner der MSE, desto genauer die Prognose des Modells. In einem Idealfall nehmen beide Kurven ab und der Validation Loss (MSE) liegt unter dem Training Loss (MSE) oder sehr nah an der Kurve des Trainingsverlustes.

Laufen die Trainings Loss und die Validation Loss Kurve nicht gegen Null, war das Modell nicht in der Lage, das Muster (engl.: Pattern) zu erkennen. In diesem Fall spricht man von einer Unteranpassung (engl.: Underfitting).

Läuft ausschließlich die Training Loss Kurve gegen Null, die Validation Loss Kurve aber nicht, bezeichnet man dieses Problem als Überanpassung (engl.: Overfitting), das Modell hat sich zu stark an die Trainingsdaten angepasst und kann neue Daten nicht mehr generalisieren. Eine solche Überanpassung ist beispielhaft in der Abbildung 51 dargestellt.




Abbildung 51: Beispiel für Überanpassung (Overfitting) (Quelle: eigene Darstellung)

Auf der Grundlage dieser beiden Kurven kann man die Leistung des Modells im Gesamten bewerten und eine Überanpassung oder Unteranpassung erkennen, um das Modell entsprechend zu optimieren.

Neben der Wahl des Optimierers³⁰ (engl.: Optimizers) und der Aktivierungsfunktion kann die Leistungsfähigkeit des Modells durch sogenannte Hyperparameter beeinflusst werden. Diese Hyperparameter ermöglichen eine Feinabstimmung des Modells, um seine Leistungsfähigkeit zu optimieren. Im folgenden Unterkapitel werden die Grundlagen der Hyperparameter erläutert, um ein besseres Verständnis ihrer Wirkung auf das Modell zu ermöglichen (vgl. Kapitel 2.3.3.7).

2.3.3.7 Hyperparameter

Hyperparameter sind sogenannte Konfigurationsvariablen, die für die Trainingsphase des neuronalen Modelles verwendet werden. Diese werden vor dem Training des Modelles festgelegt

³⁰ Der Optimierer (engl.: Optimizers) ist eine mathematische Funktion, die zu Minimierung des Loss eingesetzt wird. Die Optimierung wird durch eine iterative Anpassung der Gewichte und Bias-Werte der Neuronen erreicht. Ein bekannter Optimierungsalgorithmus ist der Gradientenabstieg.

und beeinflussen die Leistung des Modells. Die Wahl der richtigen Hyperparameter ist ein wesentlicher Bestandteil der Optimierung eines Modells.

Beispiele für gängige Hyperparameter sind:

- Lernrate (engl.: Learning rate): Schrittgröße bei der Gewichtsanzpassung während des Trainings,
- Schichten (engl.: Layers): die Anzahl der Schichten im neuronalen Netzwerk,
- Neuronen (engl.: Neurons): Anzahl der Neuronen pro Schicht,
- Chargengröße (engl.: Batchsize): Anzahl der Trainingsdaten pro Optimierungsschritt,
- Epochen (engl.: Epochs): Anzahl der Trainingsdurchläufe.

In der Regel werden die Hyperparameter manuell festgelegt, es gibt aber auch spezielle Bibliotheken und Frameworks, bei denen Algorithmen die besten Hyperparameter automatisch ermitteln. Dazu gehören beispielsweise Hyperopt [110], KerasTuner [111] und Optuna [112].

2.3.3.8 Bibliotheken

In der Informatik existieren für Programmierer eine Vielzahl von verschiedenen Bibliotheken, die häufig verwendete Funktionen enthalten. Diese Funktionen können durch das Importieren der entsprechenden Bibliothek in den Programmcode genutzt werden.

Die in dieser Arbeit verwendeten Bibliotheken werden in diesem Kapitel kurz erläutert.

- **Keras:** Keras ist eine Open-Source-Bibliothek, die eine Python-Schnittstelle für künstliche neuronale Netze zur Verfügung stellt. Keras fungiert u.a. als Schnittstelle für TensorFlow (Frontend für TensorFlow), unterstützt seit der Version 3.0 unter dem neuen Namen „Keras Core“ aber auch JAX und PyTorch [113].

Webseite: keras.io

- **Matplotlib:** Bei Matplotlib handelt es sich um eine Plot-Bibliothek für die Programmiersprache Python und deren Erweiterung NumPy für numerische Mathematik. Matplotlib wurde als open source Alternative zu MATLAB entwickelt. Pyplot ist ein Modul von Matplotlib, das ein Interface, angelehnt an MATLAB, zur Verfügung stellt.

Webseite: matplotlib.org

- **NumPy:** NumPy ist eine Python-Bibliothek, die verwendet wird, um mit Arrays zu arbeiten.

Webseite: numpy.org

- **Pandas:** Pandas ist eine Python-Bibliothek für die Analyse von Daten.

Webseite: pandas.pydata.org

- **Scikit-learn:** Scikit-learn (früher bekannt als scikits.learn bzw. sklearn) ist eine Open-Source-Bibliothek für maschinelles Lernen, die für die Programmiersprache Python entwickelt wurde.

Webseite: scikit-learn.org

- **Seaborn:** Seaborn ist eine auf matplotlib basierende Python-Bibliothek zur Visualisierung von Daten.

Webseite: seaborn.pydata.org

- **TensorFlow:** TensorFlow ist eine freie und Open-Source-Softwarebibliothek für maschinelles Lernen und künstliche Intelligenz.

TensorFlow wurde bei Google durch die Abteilung Google Brain entwickelt [114].

Webseite: tensorflow.org

3 Analyse verschiedener Verfahren zur Lebensdauerermittlung

3.1 Einleitung

Aufgrund der fehlenden Relevanz der stochastischen Methoden für das Bauwesen, bedingt durch die hohe Kostenintensität (siehe Kapitel 2.2.2), werden in diesem Kapitel ausschließlich die anwendungsorientierten Näherungsmethoden verglichen.

Die anwendungsorientierten Näherungsverfahren zielen darauf ab, die Lebensdauern mit Hilfe von Annahmen möglichst plausibel abzuschätzen. Aufgrund der fehlenden oder marginalen Berücksichtigung relevanter Einflussgrößen sind diese Methoden bisher nur als grobe Approximation anzusehen [7].

Wie auch Ritter [7] in seiner Dissertation feststellt, erscheint für einen allgemeinen Ansatz zur Entwicklung eines Alterungsmodells nur die ISO 15686 geeignet, da sie allgemeine Rahmenbedingungen für die Lebensdauerbestimmung vorgibt und somit harmonisierte Lebensdauerdaten von Bauprodukten in transparenter Form ermittelt werden können.

Anschließend werden die Ansätze von Ritter sowie Bahr und Lennerts zur Verbesserung der Ergebnisse der Faktorenmethode nach ISO 15686 erläutert. Die Grundlagen zu diesen Ansätzen, die bereits in Kapitel 2.2 behandelt wurden, werden in diesem Kapitel vertieft und im Einzelnen detailliert ergänzt.

Die Reihenfolge der Kapitel ist analog zur Komplexität der Methoden.

3.2 Kennwertmethode

Die Kennwertmethode bezeichnet die Verwendung der in der Literatur veröffentlichten Referenzwert für die Lebensdauer von Bauteilen. Dabei wird unabhängig jeder Randbedingung ein statistischer Referenzwert als Lebensdauer für ein spezifisches Bauteil angenommen, das entspricht den anwendungsorientierten Näherungsverfahren.

In der Tabelle 4 wurden beispielhaft einige dieser Veröffentlichungen aus den Jahren 2000 bis 2023 zusammengefasst.

Tabelle 4: Aktuelle Lebensdauerdaten in der Literatur, Stand 02/2023 (Quelle: eigene Darstellung nach [7] S. 50)

| Jahr | Verfasser | Titel |
|------|--|---|
| 2001 | Bundesamt für Bauwesen und Raumordnung, Berlin | Leitfaden nachhaltiges Bauen |
| 2001 | Hellerforth | Facility Management – Immobilien optimal verwalten |
| 2003 | Schweizer Eidgenössisches Departement für Verteidigung, Bevölkerungsschutz und Sport | Technische Weisung Beurteilung von Energiesystemen und Energiesparmaßnahmen |
| 2004 | Institut für Bauforschung e.V., Hannover | Lebensdauer der Baustoffe und Bauteile zur Harmonisierung der wirtschaftlichen Nutzungsdauer im Wohnungsbau |

| | | |
|-------------|--|--|
| 2004 | Schmitz, Krings, Dahlhaus, Meisel | Instandsetzung / Sanierung / Modernisierung / Umnutzung |
| 2006 | Sachverständigen-Landesverband Steiermark und Kärnten, Österreich | Nutzungsdauerkatalog 2006 |
| 2006 | Institut für Erhaltung und Modernisierung von Bauwerken e.V., Berlin | Lebensdauer von Bauteilen und Bauteilschichten |
| 2007 | Institute for Building Operations-Research, Nürtingen-Geislingen | Technische Lebensdauern |
| 2008 | Bundesministerium für Verkehr, Bau und Stadtentwicklung, Berlin | Zwischenauswertung mittlere Lebensdauern |
| 2008 | Arbeitsgruppe Bund Technischer Experten e.V., Essen | Lebensdauer von Bauteilen |
| 2008 | Schweizerischer Mieterinnen- und Mieterverband, Zürich | Lebensdauer von Bauteilen |
| 2009 | Bundesministerium für Verkehr, Bau und Stadtentwicklung, Berlin | Lebensdauer von Bauteilen und Bauteilschichten |
| 2009 | Bundesinstitut für Bau-, Stadt- und Raumforschung, Berlin | Nutzungsdauerangaben von ausgewählten Bauteilen der Kostengruppen 300, 400 und 500 nach DIN 276-1 |
| 2011 | Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen, Berlin | Nutzungsdauern von Bauteilen für Lebenszyklusanalysen nach Bewertungssystem Nachhaltiges Bauen (BNB) |
| 2011 | Dr.-Ing. Frank Ritter | Lebensdauer von Bauteilen und Bauelementen |
| 2014 | Schweizerischer Mieterinnen- und Mieterverband, Zürich | Paritätische Lebensdauertabelle |
| 2017 | Schweizerischer Mieterinnen- und Mieterverband, Zürich | Paritätische Lebensdauertabelle: Bewertung von Einrichtungen in Wohn- und Geschäftsräumen |
| 2017 | Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen, Berlin | Nutzungsdauern von Bauteilen für Lebenszyklusanalysen nach Bewertungssystem Nachhaltiges Bauen (BNB) |
| 2019 | Schweizerischer Mieterinnen- und Mieterverband, Zürich | Paritätische Lebensdauertabelle: Bewertung von Einrichtungen |

Diese Lebensdauertabellen (vgl. Tabelle 4) enthalten in den meisten Fällen keine konkreten Angaben zu den Quellen und sind nicht an spezifische Randbedingungen bei der Anwendung gebunden. Vergleicht man die Lebensdauerangaben eines Bauteils, so fällt auf, dass die Angaben zu den Lebensdauern in den jeweiligen Veröffentlichungen aufgrund der unterschiedlichen angenommenen Randbedingungen teilweise stark divergieren. Auf die Randbedingungen wird im Kapitel 5 näher eingegangen.

Das Problem der divergierenden Werte in den Lebensdauertabellen wurde bereits in der Abbildung 2 am Beispiel eines Kunststofffensters demonstriert.

Aufgrund der fehlenden Berücksichtigung von Randparametern können solche Referenzlebensdauern nur für allgemeine Abschätzungen verwendet werden, für eine möglichst präzise Bestimmung der Lebensdauern spezifischer Bauteile ist die Methode jedoch nicht geeignet.

3.3 Referenzfaktorenmethode von Tomm, Rentmeister und Finke

Im Jahr 1995 veröffentlichte das Landesinstitut für Bauwesen des Landes Nordrhein-Westfalen³¹ (ehemalige Bezeichnungen: Landesinstitut für Bauwesen und angewandte Bauschadensforschung bzw. „Zentrale Planungsstelle zur Rationalisierung von Landesbauten Nordrhein-Westfalen“ [115]) in Zusammenarbeit mit der ARGEBAU-Fachkommission „Standardisierung und Rationalisierung“ unter den Autoren Tomm, Rentmeister und Finke das „Verfahren zur systematischen Erfassung und Steuerung von Instandhaltungsmaßnahmen an Gebäuden“ [7, 51].

Die Ausarbeitung unterteilt sich in drei Teile, wobei im ersten Teil das Verfahren, die Bauteile, die Lebensdauern, die Einflussfaktoren sowie die Inspektions- und Wartungsintervalle und deren Auswirkungen auf die Kosten erläutert werden. Der zweite Teil beinhaltet die Vorgehensweise der geplanten Instandhaltung am Beispiel ausgewählter Projekte. Der letzte Teil enthält die Dokumentation weiterer dreißig Pilotprojekte aus Nordrhein-Westfalen [7, 51].

Grundlage für dieses Verfahren ist ein Bauteilkatalog mit etwa hundert verschiedenen Bauteilgruppen und Referenzlebensdauer, in dem die für die Instandhaltung relevanten Bauteile auf der Basis der Struktur der DIN 276 gegliedert sind [7, 11].

Die Lebensdauern von Tomm, Rentmeister und Finke sind aus den Erfahrungen von Experten, Herstellern und den Autoren abgeleitet [7].

Die Autoren gehen bei den angegebenen mittleren Lebenserwartungen der Bauteile von einer durchschnittlicher Nutzungs-, Qualitäts-, Umwelt- und Instandhaltungsintensität aus [7, 11].

In einem ersten Schritt werden die relevanten Informationen über das Gebäude und seine Bauteile erfasst und aufgelistet. Anschließend werden die mittleren Lebensdauern der instandhaltungsrelevanten Bauteile aus dem Bauteilkatalog angesetzt und die Lebensdauern über die sogenannten Abzugsfaktoren und Einflussfaktoren angepasst. Abzugsfaktoren sind dabei beispielsweise das Alter des Bauteils oder der Grad der Abnutzung.

Als Einflussfaktoren werden die Nutzung, die Ausführungs- und Bauteilqualität, die Umwelteinflüsse sowie die Intensität der Instandhaltung berücksichtigt. Bei der Alterung der Bauteile wird von einem linearen Abbau des Abnutzungsvorrates ausgegangen.

Damit sollte es möglich sein, die mittlere Lebensdauer in Abhängigkeit von den spezifischen Randbedingungen nach oben oder unten zu korrigieren. Eine Systematik zur Bestimmung der Größe der Faktoren wird von den Autoren jedoch nicht vorgegeben. Es werden lediglich Beispiele für Einflussfaktoren in positiver und negativer Richtung beschrieben.

³¹ Das Landesinstitut für Bauwesen des Landes Nordrhein-Westfalen (LB) ist eine Einrichtung des Ministeriums für Städtebau und Wohnen, Kultur und Sport des Landes Nordrhein-Westfalen (MSWKS).

Die Anpassung der Lebensdauer ist daher rein subjektiv und hängt von der individuellen Erfahrung des jeweiligen Anwenders ab.

3.4 Faktorenmethode nach der ISO 15686

Fünf Jahre nach der Veröffentlichung der Referenzfaktorenmethode von Tomm, Rentmeister und Finke wurde im Jahr 2000 die ISO 15686 mit der sogenannten Faktorenmethode veröffentlicht. Dieses Unterkapitel beschäftigt sich ausschließlich mit der Methode der ISO 15686, weitere Informationen zu der Norm und ihrem Aufbau befinden sich in Kapitel 2.2.3.

Das Verfahren basiert auf der bereits erläuterten Referenzfaktorenmethode und einer 1993 in Japan veröffentlichten Methode zur Bestimmung von Lebensdauern [11]. Die Faktorenmethode versucht, in einem detaillierteren Umfang unter Berücksichtigung der tatsächlichen Umwelteinflüsse eine präzisere und spezifischere Lebensdauer zu ermitteln.

Die 15686 definiert dafür im achten Teil [53], wie in der Tabelle 5 illustriert, drei Gruppen mit insgesamt sieben verschiedenen Einflussfaktoren (A bis G).

Tabelle 5: Faktoren der ISO 15686 - Teil 8 (Quelle: eigene Darstellung nach [53] S. 16)

| Gruppe | Faktor | Kategorie |
|---------------------|----------|-------------------------------|
| Qualität | A | Bauteilqualität ³² |
| | B | Planungsqualität |
| | C | Ausführungsqualität |
| Umwelt | D | Umwelt (innen) |
| | E | Umwelt (außen) |
| Nutzungsbedingungen | F | Nutzungszustand |
| | G | Instandhaltungsqualität |

Im Anhang der ISO 15681 (Teil 8) wird in den Beispielen auf Seite 23 im Anhang „Annex C“ auch am Beispiel von Stahlstürzen erläutert, was bei der Bewertung der jeweiligen Faktoren zu berücksichtigen ist. Eine in die deutsche Sprache übersetzte Darstellung dieser Erläuterungen finden Sie in der

³² In der englischen Norm ISO 15686 – Teil 8 wird der Faktor A als „inhärentes Leistungsniveau“ bezeichnet, aufgrund der Erläuterung in der ISO, dass das inhärente Leistungsniveau die Qualität des Bauteils im Auslieferungszustand darstellt, wird der Faktor A hier mit dem deutschen Begriff Bauteilqualität bezeichnet.

Tabelle 6.

Tabelle 6: Erläuterungen der zu berücksichtigenden Faktoren nach der ISO 15686 - Teil 8

(Quelle: eigene Darstellung nach [53] S. 23)

| Gruppe | Faktor | zu berücksichtigen |
|---------------------|----------|---|
| Qualität | A | Art und Qualität des Materials. Langlebigkeitsmerkmale, z. B. Imprägnierung. |
| | B | Einzelheiten der Konstruktion, z. B. Verbindungen, Befestigungen |
| | C | Baustellenarbeiten, z. B. nicht nach BS 8000 ³³ , mit konkreten Beispielen |
| Umwelt | D | Besondere Merkmale, z. B. Kondensation |
| | E | Besondere Merkmale, z. B. maritim oder verschmutzt (Luft) |
| Nutzungsbedingungen | F | Besondere Merkmale, z. B. Vandalismus |
| | G | Zyklisch, einschließlich Qualität |

Für die Ermittlung der geschätzten Lebensdauer bzw. ESL (engl.: estimated service life) wird in der ISO 15681 folgende Formel angegeben (vgl. 3.1 bzw. 3.2).

Die Basis bildet dabei die Referenzlebensdauer bzw. RSL (engl.: reference service life) des zu bewertenden Bauteiles, welche die Lebensdauer eines Bauteiles unter durchschnittlichen Bedingungen beschreibt.

$$t_{ESL} = t_{RSL} \times \Phi(A, B, C, D, E, F, G) \quad 3.1$$

(Quelle: [53] S. 14)

$$t_{ESL} = t_{RSL} \times \Phi A \times \Phi B \times \Phi C \times \Phi D \times \Phi E \times \Phi F \times \Phi G \quad 3.2$$

(Quelle: [53] S. 26)

Eine Darstellung der Formel mit deutschen Begriffen kann folgendermaßen aussehen (vgl. 3.3).

$$\text{geschätzte Lebensdauer} = \text{Referenzlebensdauer} \times \text{Faktor A} \times \text{Faktor B} \times \text{Faktor C} \times \text{Faktor D} \times \text{Faktor E} \times \text{Faktor F} \times \text{Faktor G} \quad 3.3$$

³³ Technische Spezifikation des „British Standards Institution“: BS 8000-8:2023 Workmanship on construction sites Design and installation of dry lining systems. Code of practice

Die geschätzte Lebensdauer ergibt sich nach dieser Formel durch Multiplikation der Referenzlebensdauer mit den in Tabelle 5 angegebenen Faktoren. Theoretisch können die Werte dieser Faktoren zwischen 0 und unendlich liegen.

In der Norm wird jedoch darauf hingewiesen, dass die Werte realistischerweise mindestens zwischen 0,8 und 1,2, im besten Fall zwischen 0,9 und 1,1 liegen sollten [53].

Wie bereits Ritter [7] feststellte, ist der Ansatz der ISO 15685 mit der rechnerischen Berücksichtigung spezifischer Einflussfaktoren sehr sinnvoll. Allerdings ist eine Anwendung der Methode nicht ohne weiteres möglich, da die Norm weder Angaben zu Referenzlebensdauern noch zu den Werten der Faktoren macht [7].

Bezüglich der Referenzlebensdauern empfiehlt die Norm die Verwendung von Angaben aus der Literatur oder von Herstellern, welcher aber, wie bereits in Kapitel 1 erläutert, qualitativ nicht unbedingt den gewünschten Anforderungen entsprechen. Eine ungenaue Referenzlebensdauer führt bei dieser Methode zwingend zu einem ungenauen Ergebnis.

Wie bereits von Bahr und Lennerts [11] angemerkt, lässt sich zudem kritisieren, dass die Gleichgewichtung aller Faktoren im Widerspruch zur Realität steht.

In der Realität ist davon auszugehen, dass die Wirkung der einzelnen Faktoren sehr unterschiedlich ist.

3.5 Ansatz von Ritter

Ritter [7] versuchte 2011 in seiner Dissertation Lösungen für die Schwachstellen der Faktorenmethode der ISO 15686 zu finden. Seine Methodik sieht vor, die Faktorenmethode mit einer Wahrscheinlichkeitsverteilungen zu erweitern, so dass auch Lebensdauerprognosen bei überwiegend unbekanntem Einflussgrößen möglich sind. Fehlende Werte bei den Referenzlebensdauern hat Ritter [7] durch eine eigene Datenerhebung ergänzt, um eine ausreichend große Menge an belastbaren Datensätzen zu erhalten.

Dabei hat er die Unterschiede in der Relevanz der einzelnen Einflussfaktoren ermittelt, um den großen Kritikpunkt der Faktorenmethode, dass alle Faktoren gleich gewichtet werden, zu verbessern.

Kern der Arbeit von Ritter ist jedoch die Begrenzung der Wirkung der Einflussfaktoren. Von der Begrenzung der berechneten spezifischen Lebensdauern durch die aus der Datenerhebung ermittelten Minimal- und Maximalwerte verspricht er sich eine wesentliche Verbesserung des Modells und damit eine höhere Akzeptanz in der Praxis [7].

In der Tabelle 7 ist ein Auszug der Ergebnisse von Ritter für die Bauteilgruppe Fenster dargestellt.

Tabelle 7: Technische Lebensdauer mit Einflussgrenzwerten von Fenstern nach Ritter (Quelle: [7] S. 132)

| | Technische Lebensdauer [a] | | | A | B | C | D | E | F | G |
|-------------------|----------------------------|--------------------|--------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | TLD _{min} | TLD _{ref} | TLD _{max} | max min | max min | max min | max min | max min | max min | max min |
| Alufenster | 10 | 47 | 119 | 1,13 0,84 | 1,09 0,88 | 1,15 0,79 | 1,06 0,84 | 1,25 0,69 | 1,18 0,79 | 1,14 0,83 |
| Holzfenster | 3 | 36 | 88 | 1,13 0,76 | 1,09 0,82 | 1,14 0,69 | 1,05 0,76 | 1,24 0,56 | 1,18 0,69 | 1,13 0,75 |
| Kunststofffenster | 3 | 38 | 83 | 1,11 0,75 | 1,08 0,82 | 1,12 0,68 | 1,05 0,76 | 1,21 0,55 | 1,15 0,68 | 1,11 0,75 |

An dem Beispiel Fenster hat Ritter für die Faktoren der Faktorenmethode definiert, dass der Faktor A (Bauteilqualität) ausschließlich Werte zwischen 0,84 und 1,13 annehmen darf. Für das Alufenster ergibt sich nach Ritter eine maximale Lebensdauer von 119 Jahren ($TLD_{max} = TLD_{ref} \times A_{max} \times B_{max} \times C_{max} \times D_{max} \times E_{max} \times F_{max} \times G_{max}$).

Die Realitätsnähe solcher Werte ist zu hinterfragen.

Zusammenfassend kann gesagt werden, dass Ritter mit seinen Einflussgrenzen einen Ansatz entwickelt hat, der in der ursprünglichen Faktorenmethode fehlt und diese an dieser Stelle sinnvoll ergänzt.

Allerdings muss auch gesagt werden, dass, wie am Beispiel der Tabelle 5 zu sehen ist, trotz der von Ritter gesetzten Grenzen immer noch ein sehr großer subjektiver Spielraum bei der Bestimmung der Lebensdauer besteht.

3.6 Ansatz von Bahr und Lennerts

Ein weiterer Ansatz zur Bestimmung spezifischer Lebensdauern wurde im Jahr 2010 von Bahr und Lennerts [11] unter dem Titel „Lebens- und Nutzungsdauer von Bauteilen“ veröffentlicht.

Bahr und Lennerts versuchen die Faktorenmethode der DIN ISO 15686 zu optimieren, indem sie die in der DIN ISO 15686 genannten Faktoren in Haupt- und Nebenkriterien unterteilen und unterschiedlich gewichten.

Darüber hinaus geben sie Empfehlungen für die zu verwendenden Referenzlebensdauern und restriktive Vorgaben für die Höhe der Werte der einzelnen Faktoren.

Sie stellen fest, dass eine genauere Vorhersage der Lebensdauer eines Bauteils im Idealfall durch eine weitere Differenzierung der Einflussgrößen in materialspezifische Kriterien ermöglicht werden könnte. Dass diese Vorgehensweise jedoch einen erheblichen Aufwand sowie ein hohes Maß an spezifischem Fachwissen erfordere.

Sie empfehlen daher die Erstellung von Expertendatenblättern³⁴ für einzelne Bauteile, um eine möglichst objektive Bewertung zu gewährleisten und die Subjektivität der Bewertung zu minimieren [7].

Auf der Webseite des BMWSB [56] (Stand 01/2023) wird empfohlen, bei einer projektspezifischen Lebenszyklusbetrachtung unter Verwendung der vom BBSR veröffentlichten Lebensdauern die Faktoren-Methode gemäß ISO 15686, unter Berücksichtigung des Forschungsberichts von Bahr und Lennerts [14], zu verwenden.

³⁴ Vorgefertigte Formblätter mit Ausfüllhilfen, die eine Verzerrung durch subjektive Einflüsse beim Ausfüllen verhindern sollen.

4 Bauteile im Bauwesen nach DIN 276

4.1 Einleitung

Für die Ermittlung der Kosten im Bauwesen bildet die Norm DIN 276 die essenzielle Grundlage, neben den Stufen der Kostenermittlung enthält diese die sogenannte Kostengliederung. Die Kostengliederung besteht aus drei Ebenen, welche durch eine dreistellige Ordnungszahl gekennzeichnet sind. Dadurch ermöglicht es die DIN 276, jede Gruppe von Bauelementen eines Gebäudes im Hochbau über die entsprechende Kostengruppen-Ordnungszahl bis zu einer gewissen Detaillierungsebene eindeutig zu identifizieren.

Kostengruppen werden in der Regel mit der Abkürzung KG³⁵ und der dazugehörigen Ordnungszahl referenziert.

In der ersten Ebene werden, wie in der Tabelle 8 grafisch veranschaulicht, die Gesamtkosten eines Bauwerks in acht Kostengruppen aufgeteilt [38].

Tabelle 8: Erste Ebene der Kostengliederung nach DIN 276 (Quelle: eigene Darstellung nach [38])

| Kostengruppe (KG) | |
|--------------------------|------------------------------|
| 100 | Grundstück |
| 200 | Vorbereitende Maßnahmen |
| 300 | Bauwerk – Baukonstruktion |
| 400 | Bauwerk – Technische Anlagen |
| 500 | Außenanlagen |
| 600 | Ausstattung |
| 700 | Baunebenkosten |
| 800 | Finanzierung |

Die erste Ebene untergliedert sich weiter in eine zweite und dritte Ebene [38], so befinden sich beispielsweise in der zweiten Ebene der KG folgende weitere Bauteile (vgl. Tabelle 8):

³⁵ Manchmal werden Kostengruppen in der Literatur auch mit KGR oder KGr abgekürzt.

Tabelle 9: Zweite Ebene der Kostengliederung am Beispiel der KG 300 nach DIN 276 (Quelle: eigene Darstellung nach [38])

| Kostengruppe (KG) | |
|--------------------------|---|
| 300 | Bauwerk – Baukonstruktion |
| | 310 Baugrube, Erdbau |
| | 320 Gründung, Unterbau |
| | 330 Außenwände/Vertikale Baukonstruktionen, außen |
| | 340 Innenwände/Vertikale Baukonstruktionen, innen |
| | 350 Decken/Horizontale Baukonstruktionen |
| | 360 Dächer |
| | 370 Infrastrukturanlagen |
| | 380 Baukonstruktive Einbauten |
| | 390 Sonstige Maßnahmen für Baukonstruktionen |

Die Kostengruppen der zweiten Ebene sind wiederum in einer dritte Ebene untergliedert [38], dazu enthält Tabelle 10 ein Beispiel an der KG 330.

Tabelle 10: Ausschnitt der dritten Ebene der Kostengliederung am Beispiel der KG 330 nach DIN 276 (Quelle: eigene Darstellung nach [38])

| Kostengruppe (KG) | |
|--------------------------|---|
| 300 | Bauwerk – Baukonstruktion |
| | 310 Baugrube, Erdbau |
| | 320 Gründung, Unterbau |
| | 330 Außenwände/Vertikale Baukonstruktionen, außen |
| | 331 Tragende Außenwände |
| | 332 Nichttragende Außenwände |
| | 333 Außenstützen |
| | 334 Außenwandöffnungen |
| | 335 Außenwandbekleidungen, außen |
| | 336 Außenwandbekleidungen, innen |
| | 337 Elementierte Außenwandkonstruktionen |
| | 338 Lichtschutz zur KG 300 |
| | 339 Sonstiges zur KG 300 |
| | 340 Innenwände/Vertikale Baukonstruktionen, innen |

Demzufolge identifiziert die KG 331 die tragenden Außenwände eines Gebäudes. Diese etablierte Struktur zur Identifikation von Bauteilen wurde ursprünglich für die Kostenermittlung entwickelt, um Kosten eindeutig Bauteilgruppen bzw. Bauteilen zuzuordnen, wie in DIN 276 [38] beschrieben.

Im Bereich der Instandhaltung wird heute häufig auf diese bestehende Struktur zurückgegriffen, um Zustände einzelnen Bauteilen eindeutig zuzuordnen.

In der Praxis wird oft im Kontext der DIN 276 von Kostengruppen gesprochen. Diese Begriffe sind jedoch nicht in der DIN 276 definiert, sondern stammen aus der weit verbreiteten Software SIRADOS, einer Datenbank für Baupreise. In SIRADOS werden die Kostengruppen der ersten Ebene der DIN 276 als Makroelemente, die Kostengruppen der zweiten Ebene als Grobelemente und die der dritten Ebene als Feinelemente bezeichnet.

In der Praxis wird im Zusammenhang mit der DIN 276 häufig von Grob- oder Feinelementen gesprochen. Diese Begriffe sind jedoch nicht in der DIN 276 definiert [38], sondern stammen aus der weit verbreiteten Baupreisdatenbank SIRADOS [116].

In SIRADOS werden die Kostengruppen der ersten Ebene der DIN 276 als Makroelemente, die Kostengruppen der zweiten Ebene als Grobelemente und die Kostengruppen der dritten Ebene als Feinelemente definiert [116].

Für die Untersuchung von Lebensdauern von Bauteilen liegt der Fokus in dieser Arbeit auf einer kleinen Teilmenge der KG 300. Die Auswahl der für diese Arbeit relevanten Kostengruppen ist in Kapitel 6 detailliert erläutert.

4.2 Erweiterung der Kostengruppenstruktur

Der für eine Kostenermittlung ausreichende Detaillierungsgrad von drei Ebenen stößt im Bereich der Instandhaltung insbesondere aufgrund der Werkstoffunabhängigkeit an seine Grenzen.

So ist es für die Kostenermittlung irrelevant, aus welchem Werkstoff die Bauelemente der Kostengruppe bestehen, für die Instandhaltung aber nicht. Für eine Lebensdauerprognose einzelner Bauelemente müssen werkstoffspezifische Lebensdauern angesetzt werden. Eine tragende Außenwand aus Beton hat beispielsweise eine andere Lebensdauer als eine tragende Außenwand aus dem Werkstoff Holz. An dieser Stelle fehlt in der Kostengruppenstruktur der DIN 276 der Detaillierungsgrad. Darüber hinaus wird in der Gliederung auch nicht zwischen den Ausführungsstandards wie einfach oder hochwertig differenziert. Außerdem werden in manchen Kostengruppen unterschiedliche Bauteile in einer einzigen Gruppe zusammengefasst, so beinhaltet die Kostengruppe 334 beispielsweise Außentüren sowie auch Außenfenster.

Diese fehlenden Differenzierungen verhindern die Verwendung hoch individualisierter Lebensdauern.

Aufgrund dieses Umstandes wurde iterativ in den Projekten FM[^]EM [25], FM[^]EM II [26] sowie OPKI [19] der Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau (RPTU) die Kostengruppenstruktur der DIN 276 um eine vierte Ebene erweitert.

In der Tabelle 11 ist die Erweiterung der ursprünglichen Kostengliederung um die vierte Ebene am Beispiel der KG 334(0) und KG 335(0) dargestellt. Aus Gründen der Konsistenz werden vierstellige Ordnungszahlen anstelle der dreistelligen nach DIN 276 verwendet.

Tabelle 11: Kostengliederung mit vier Ebenen (Quelle: eigene Darstellung nach [19])

| Kostengruppe (KG) | | |
|-------------------|---------------------------|---|
| 3000 | Bauwerk – Baukonstruktion | |
| | 3100 | Baugrube, Erdbau |
| | 3200 | Gründung, Unterbau |
| | 3300 | Außenwände/Vertikale Baukonstruktionen, außen |
| | 3310 | Tragende Außenwände |
| | 3320 | Nichttragende Außenwände |
| | 3330 | Außenstützen |
| | 3340 | Außenwandöffnungen (Durchschnitt) |
| | 3341 | Außenfenster |
| | 3342 | Außentüren |
| | 3350 | Außenwandbekleidungen, außen (Durchschnitt) |
| | 3351 | Putz |
| | 3352 | Mauerwerk |
| | 3353 | Platten bzw. Stein |
| | 3354 | Holz |
| | 3355 | Metall |
| | 3360 | Außenwandbekleidungen, innen |
| | 3370 | Elementierte Außenwandkonstruktionen |
| | 3380 | Lichtschutz zur KG 300(0) |
| | 3390 | Sonstiges zur KG 300(0) |
| | 3400 | Innenwände/Vertikale Baukonstruktionen, innen |

Untergliedert sich eine Kostengruppen der dritten Ebene weiter in eine vierte Ebene, so referenziert die Kostengruppe der dritten Ebene auf den ursprünglichen Durchschnittswert der untergeordneten Elemente.

Für das Beispiel der KG 3340 „Außenwandöffnungen (Durchschnitt)“ aus der Tabelle 5 bedeutet das, dass die KG 3340 den Durchschnitt der Werte der KG 3341 sowie der KG 3342 repräsentiert. Der Gedanke dahinter ist der, dass die Zustandsinformationen eines Bauteiles, welche durch diese Nummer referenziert werden sollen, manchmal nicht für jedes untergeordnete Element bestimmen werden können oder vorliegen. In einem solchen Fall kann eine durchschnittliche Zustandsinformation für die dritte Ebene ermittelt werden. Dieses Vorgehen bezieht sich ausschließlich auf die dritte Ebene.

Dabei gilt anzumerken, dass die Erweiterung zum aktuellen Stand ausschließlich die Kostengruppen 300 bzw. 3000 (Bauwerk – Baukonstruktion) und 400 bzw. 4000 (Bauwerk – Technische Anlagen) betrifft.

Die erweiterte Struktur mit vier Ebenen der Kostengruppen 300(0) bis einschließlich Kostengruppen 360(0) kann dem Anhang A 3 entnommen werden.

In der Literatur und in Arbeiten finden sich häufig Erweiterungen der Struktur der DIN 276. So wurden in den Tabellen der „Nutzungsdauern von Bauteilen für Lebenszyklusanalysen nach Bewertungssystem Nachhaltiges Bauen (BNB) (2017)“ [14] des Bundesinstitut für Bau-, Stadt- und Raumforschung die Kostengruppen um einen dreistelligen Code ergänzt, um die die 3. Ebene weitere untergliedern zu können (vgl. Abbildung 52).



**Nutzungsdauern von Bauteilen
für Lebenszyklusanalysen nach Bewertungssystem Nachhaltiges Bauen (BNB)**

| Code Nr. | KG - 2. Ebene | KG - 3. Ebene | Bauteil / Material | a | Ersatz in 50a |
|----------|-----------------------|--|--|------|---------------|
| | 320 Gründung | | | | |
| | 320 Gründung | 322 Flachgründungen | | | |
| 322.111 | | | Einzel- / Streifenfundamente | ≥ 50 | 0 |
| 322.112 | | | Fundamentplatten | ≥ 50 | 0 |
| | 320 Gründung | 323 Tiefgründungen | | | |
| 323.111 | | | Bohrpfähle, Presspfähle, Rammpfähle, Pfahlwände, Schlitzwände, Spundwände, Trägerbohlwände | ≥ 50 | 0 |
| | 320 Gründung | 324 Unterböden und Bodenplatten | | | |
| 324.111 | | | Bodenplatte | ≥ 50 | 0 |
| | 320 Gründung | 326 Bauwerksabdichtung | | | |
| 326.111 | | | Abdichtung gegen nichtdrückendes Wasser | 35 | 1 |
| | 330 Außenwände | | | | |
| | 330 Außenwände | 331 Tragende Außenwände | | | |
| 331.111 | | | Mauerwerkswand | ≥ 50 | 0 |
| 331.211 | | | Betonwand | ≥ 50 | 0 |
| 331.311 | | | Holz wand | ≥ 50 | 0 |
| 331.411 | | | Stahlbauwand | ≥ 50 | 0 |
| 331.511 | | | Lehmbauwand | ≥ 50 | 0 |
| 331.611 | | | Formsteine mit Betonfüllung | ≥ 50 | 0 |
| | 330 Außenwände | 333 Außenstützen | | | |
| 333.111 | | | Mauerwerksstütze | ≥ 50 | 0 |
| 333.211 | | | Betonstütze | ≥ 50 | 0 |

Stand: 24.02.2017

Abbildung 52: Nutzungsdauern von Bauteilen für Lebenszyklusanalysen nach Bewertungssystem Nachhaltiges Bauen (BNB) (2017) (Quelle: [14])

Anmerkung: In dieser Arbeit wird das Wort Kostengruppe synonym mit dem Wort Bauteil und Bauelement verwendet.

5 Einflussfaktoren auf die Lebensdauern von Bauelementen

5.1 Einleitung

Einflussfaktoren auf die Lebensdauern von Bauteilen sind alle Faktoren, die sich auf den Abbau des Abnutzungsvorrats (nach DIN 31051) auswirken. Diese Faktoren können je nach Art des Bauteils sehr unterschiedlich sein und werden sowohl positive als auch negative Auswirkungen auf den Verlauf des Abbaus des Abnutzungsvorrates haben. Wie in der der Abbildung 53 grafisch dargestellt, kann der Abbau des Abnutzungsvorrates beschleunigt (Kurve a) oder verzögert werden (Kurve c).




Abbildung 53: Verlauf des Zustandes eines Bauteiles unter äußeren Einflüssen (Quelle: eigene Darstellung)

Bei der Gruppierung dieser Einflussfaktoren wird in der Literatur für gewöhnlich (vgl. [30], [7]) zwischen den materiellen und immateriellen Faktoren differenziert [11], wobei bei den materiellen Faktoren auf die Faktoren A – G des 8. Teiles der ISO 15686 [53] zurückgegriffen wird (siehe Tabelle 5).

Aufgrund der bereits etablierten Struktur (Faktoren A – G nach ISO 15686) wird im Folgenden dieselbe Struktur verwendet. Der Schwerpunkt dieser Arbeit liegt auf dem Kapitel der äußeren Umwelteinflüsse (Kapitel 5.2.6), bedingt durch die thematische Beschränkung auf die Bauteile der Gebäudehülle (vgl. Kapitel 6).

Es ist zu beachten, dass in der Praxis auch andere Faktoren wie die Qualität der Ausführung, der Bauteile, der Instandhaltung und der Planung Auswirkungen auf die Gebäudehülle haben können. Diese Einflüsse werden jedoch als außerordentliche³⁶ Einflüsse für diesen

³⁶ Außerordentlich bedeutet in diesem Zusammenhang, dass im Regelfall von einer durchschnittlichen Ausführungsqualität, Bauteilqualität, Instandhaltungsqualität sowie Planungsqualität auszugehen ist.

Anwendungsfall betrachtet und daher vernachlässigt. Ebenso wird die Nutzungsart (Nutzungszustand nach Tabelle 5, siehe Kapitel 5.2.7) vernachlässigt, begründet mit einer identischen Nutzungsart über alle betrachteten Gebäude.

Der Fokus dieser Arbeit liegt ausschließlich auf den äußeren Umwelteinflüssen, da deren Varianz unvermeidbar ist und die Annahme getroffen wird, dass für gewöhnlich die Gebäudehülle nur durch äußere Umwelteinflüsse signifikant beeinflusst wird.

Der Vollständigkeit halber werden diese Faktoren trotzdem im Kapitel 5.2 aufgeführt und erläutert, bei einer Weiterentwicklung des Prototyps sollte nochmal evaluiert werden, ob eine Aufnahme dieser Einflussfaktoren sinnvoll sein kann.

5.2 Materielle Einflussfaktoren

5.2.1 Einleitung

Materielle Einflussfaktoren (nach der ISO 15686 (Teil 8) [53]) sind Faktoren, die das Alterungsverhalten von Bauteilen direkt und quantifizierbar beeinflussen, indem sie den Abbauprozess des Abnutzungsvorrats beschleunigen oder verlangsamen.

Im Unterschied dazu basieren immaterielle Faktoren auf subjektiven Entscheidungen und wirken sich nicht unmittelbar auf den Abbau des Abnutzungsvorrates aus (vgl. Kapitel 5.3).

Wie bereits in der Einleitung (vgl. Kapitel 5.1) dieses Kapitels erwähnt, liegt der inhaltliche Schwerpunkt dieses Kapitels auf den äußeren Umwelteinflüssen (Kapitel 5.2.6), dennoch werden die weiteren materiellen Einflussfaktoren nach ISO 15686 (Teil 8) [53] in einem gekürzten Umfang erläutert.

Bahr und Lennerts [11] haben in ihrer Arbeit die Einflussgrößen nach ISO 15686 um den Faktor Baujahr ergänzt. Sie greifen die Untersuchung des IPBAU [55] aus dem Jahr 1994 auf, in der untersucht wurde, ob und wenn ja, welcher Zusammenhang zwischen dem Baujahr³⁷ und der Lebensdauer eines Bauteils besteht.

Nach IPBAU [55] unterscheiden sich heutige Baustoffe und Verarbeitungen erheblich zu denen, die vor einigen Jahrzehnten verwendet wurden, wodurch beispielsweise viele moderne Baustoffe eine geringere technische Lebensdauer haben, als traditionelle Baustoffe [11, 55].

Bedingt dadurch, dass das Alter somit einen indirekten Einfluss auf die Lebensdauer von Bauteilen haben kann, indem sich Baustoffe und Verarbeitung ändern, nehmen Bahr und Lennerts [11] das Baujahr als Einzelfaktor in die materiellen Einflussfaktoren auf.

Die in der Arbeit von Bahr und Lennerts [11] zitierte Grafik aus der IPBAU-Studie [55], in der die Korrelation zwischen Lebensdauer und Bauteilalter (1943 – 1983) am Beispiel „Putz“ dargestellt ist, kann im Anhang A 4 eingesehen werden, die Zusammenfassung der Ergebnisse der IPBAU-Studie bezüglich des Zusammenhanges zwischen Lebensdauer und Baujahr befindet sich ebenfalls im Anhang (vgl. Anhang A 12).

Es wurde eine gegenläufige Entwicklung bei den in dieser Arbeit ausgewerteten Bauteilen festgestellt. Die durchschnittliche Lebensdauer einer tragenden Außenwand aus dem Baujahr

³⁷ Das Baujahr ist hier als Synonym zu Erstellungsjahr bzw. Herstellungsjahr bzw. Einbaujahr zu betrachten.

2000 ist länger als die einer tragenden Außenwand aus dem Baujahr 1985, wie in der Abbildung 100 dargestellt. Bei der Betrachtung von Putz ergibt sich ein ähnliches Bild. Da sich diese Arbeit auf Gebäude mit einem Baujahr von ≥ 1973 beschränkt (vgl. Kapitel 8.2.3), können die Ergebnisse der IPBAU-Studie [55] nicht für einen Vergleich oder eine Bewertung herangezogen werden.

Basierend auf den Ergebnissen der IPBAU-Studie [55] wurde das Bauteilalter als zusätzlicher Einflussfaktor berücksichtigt. Dies hat sich später als korrekt erwiesen, wie in der Abbildung 91 ersichtlich ist.

Im Gegensatz dazu wird die gegenseitige Beeinflussung von Bauteilen in dieser theoretischen Betrachtung nicht weiter berücksichtigt. In der Praxis kann es vorkommen, dass funktionsfähige Bauteile durch angrenzende schadhafte Bauteile in ihrer Lebensdauer negativ beeinflusst werden. So können beispielsweise schadhafte Abdichtungen zum Eindringen von Wasser führen, wodurch der Abbau des Abnutzungsvorrats der vom Wasser betroffenen Bauteile drastisch beschleunigt werden kann. Diese Wechselwirkungen werden als ein Sonderfall betrachtet und deswegen nicht weiter berücksichtigt.

5.2.2 Bauteilqualität

Vorbemerkung: Wie bereits in dem Kapitel 3.4 erläutert, bezeichnet die ISO 15686 (Teil 8) den ersten Faktor (Faktor A aus der Tabelle 5) in der korrekten Übersetzung als „inhärentes Leistungsniveau“, erläutert diesen aber im weiteren Verlauf als Qualität des Bauteils im Anlieferungszustand. Zum besseren Verständnis wird daher auch in diesem Kapitel auf die direkte deutsche Übersetzung verzichtet.

Werden die Anforderungen an ein Bauteil, die u.a. durch Normen und die Leistungsbeschreibung des Planers festgelegt werden, nicht korrekt berücksichtigt, kann dies negative Auswirkungen auf die technische Lebensdauer eines Bauteils haben.

Die Qualität eines verbauten Bauteils beeinflusst direkt dessen technische Lebensdauer. Ein Bauteil von höherer Qualität hat gewöhnlich eine längere technische Lebensdauer als ein minderwertiges Bauteil.

Neben der Qualität eines Werkstoffes spielen auch die Art des Werkstoffes und mögliche Verfahren zur Verbesserung der Dauerhaftigkeit, wie beispielsweise eine Imprägnierung, eine Rolle.

Beispielsweise ist bei Attikaabdeckungen Aluminium oder Edelstahl in der Regel langlebiger als Kunststoff [14].

Vergleicht man beispielsweise Dachrinnen für die Entwässerung aus verzinktem Stahl, bei einem identischen Qualitätsstandard, ist bei einer zusätzlich beschichteten Dachrinne aus verzinktem Stahl mit einer größeren technischen Lebensdauer zu rechnen als bei einer unbeschichteten Dachrinne aus verzinktem Stahl [14].

5.2.3 Planungsqualität

Die Planung ist ein kritischer Prozess bei der Errichtung von Bauwerken, da Fehler in dieser Phase erhebliche Auswirkungen auf die Lebensdauer betroffener Bauteile haben können. Die Planungsqualität wird in der Faktorenmethode nach der ISO 15686 unter dem Faktor B (vgl. Tabelle 5) berücksichtigt.

Die Ausführungsplanung erfordert vor allem die Einhaltung der anerkannten Regeln der Technik, die sich in Weitem aus Normen, Richtlinien oder auch Unfallverhütungsvorschriften zusammensetzen.

Es ist daher von entscheidender Bedeutung, dass Planer und Ausführende über umfassende Kenntnisse dieser Regelwerke verfügen und in der Lage sind, diese in geeigneter Weise in die Planung und Ausführung von Bauvorhaben zu integrieren, um die Sicherheit und Zuverlässigkeit der beteiligten Bauteile zu gewährleisten.

So können beispielsweise Fehler bei der Planung der Bauwerksabdichtungen zu schwerwiegenden Schäden an der Bausubstanz führen, insbesondere durch Durchfeuchtung des Mauerwerks.

Die Durchfeuchtung des Mauerwerks infolge unzureichender Abdichtung kann zur Auslaugung der mineralischen Baustoffe und damit zu optischen Beeinträchtigungen sowie zu Haarrissen in der Bausubstanz führen. Insbesondere im Winter kann dies zu gravierenden Schäden führen, da das im Mauerwerk enthaltene Wasser beim Gefrieren eine Volumenvergrößerung aufweist und somit das Mauerwerk von innen heraus schädigen kann. Dies kann zu einer erheblichen Verkürzung der technischen Lebensdauer des Bauwerks führen und sollte daher vermieden werden.

Daher ist es sehr wichtig, dass die Planung von der Vorplanung bis zur Ausführungsplanung mit größter Sorgfalt und höchstem Qualitätsanspruch durchgeführt wird.

Die Anforderungen an die Planungsqualität umfassen nicht nur eine fehlerfreie, sondern auch eine funktionsfähige Planung. Diese sollte den Ausführenden die risikorelevanten Aspekte in eindeutiger und interpretationsfreier Form aufzeigen, ohne Raum für Missverständnisse zu lassen.

5.2.4 Ausführungsqualität

Neben der Qualität der Planung hat auch die Qualität der Ausführung einen Einfluss auf die Lebensdauern (Faktor C in der Faktorenmethode nach der ISO 15686, vgl. Tabelle 5).

Im Bauwesen ist ein erhöhter Zeit- und Kostendruck ein weit verbreitetes Phänomen, das häufig zu Mängeln in der Bauausführung führt [7, 11].

Insbesondere Verstöße gegen die anerkannten Regeln der Technik oder Abweichungen von den Ausführungsplänen können zu erheblichen Beeinträchtigungen der Bauteileigenschaften führen. Ein erhöhter Instandhaltungsaufwand sowie eine verkürzte Lebensdauer der Bauteile können die Folge sein [7, 11].

Um eine ausreichende Tragfähigkeit und Dauerhaftigkeit zu gewährleisten, müssen insbesondere die Vorgaben des Bewehrungsplans exakt eingehalten werden.

Bei der Herstellung der Bodenplatte ist es beispielsweise wichtig, die Bewehrung richtig zu verlegen und zu dimensionieren, um Rissbildungen im Beton zu vermeiden. Solche Risse können zu statischen Beeinträchtigungen führen und damit die Lebensdauer der Bodenplatte verkürzen und die Statik des gesamten Gebäudes gefährden.

5.2.5 Umwelt (innen)

Die Faktoren, die den Innenraum beeinflussen (Faktor D in der Faktorenmethode nach der ISO 15686, vgl. Tabelle 5), können in physikalische, chemische und biologische Faktoren

unterteilt werden. Zu den physikalischen Faktoren gehören Temperatur und Luftfeuchtigkeit, zu den chemischen Faktoren gehören Schadstoffkonzentrationen. Zu den biologischen Faktoren gehören Mikroorganismen wie Bakterien und Pilze sowie tierische Schädlinge.

Aufgrund der thematischen Beschränkung auf die Gebäudehülle werden innenräumliche Einflussfaktoren hier nicht weiter behandelt.

Eine ausführlichere Behandlung dieser Faktoren erklärt Ritter [7].

5.2.6 Umwelt (außen)

Den Einflussfaktoren „äußere Umwelteinflüsse“ wird aufgrund ihrer Relevanz für das Thema dieser Arbeit das umfangreichste Unterkapitel unter den materiellen Einflussfaktoren gewidmet.

In der Faktorenmethode nach ISO 15686 werden äußere Umwelteinflüsse unter dem Faktor E berücksichtigt (vgl. Tabelle 5). Die Norm erläutert dazu, dass in dieser Kategorie Faktoren auf Meso- oder lokaler Ebene angemessen sein können, aber auch die Berücksichtigung des Mikroklimas erforderlich sein kann. Als Beispiele für das Meso- oder lokale Klima (vgl. Tabelle 12) werden die Küstennähe und die Luftverschmutzung genannt. Für das Mikroklima (vgl. Tabelle 12) werden die Beispiele südliche Höhenlage, Windsog, ausgeprägte Höhenlage und Salzsprühnebelzone aufgeführt. Außerdem erwähnt die ISO 15686, dass Kombinationen aus verschiedenen Faktoren, wie beispielsweise Wasser und Frost, kritische Auswirkungen haben können.

Eine Erläuterung der in der ISO 15686 verwendeten klimatologischen Begriffe können der Tabelle 12 entnommen werden.

Tabelle 12: Definitionen der klimatologischen Begriffe des Deutschen Wetterdienstes (Quelle: [117])

| Klima | Erläuterung |
|----------------|--|
| Lokalklima | „Das Klima an einem konkreten Ort wird als Lokalklima bezeichnet. Es ist eingebettet in das Regionalklima und wird zusätzlich durch Relief und Flächennutzung in der näheren Umgebung des Ortes bestimmt.“ [117] |
| Mesoklima | <p>„Unter Mesoklima versteht man den Bereich, der zwischen dem Mikroklima und dem Makroklima liegt. Während das Makroklima hauptsächlich von großskaligen und das Mikroklima vor allem von kleinskaligen, lokalen Prozessen beeinflusst ist, ist es im Mesoklima eine Mischung von beiden. Damit umfassen die Skalen der mesoskaligen Phänomene etwa eine horizontale Ausdehnung von ca. 1 bis 2000 km und eine typische Lebensdauer von einer Stunde bis hin zu einer Woche. Geländeform, Hangneigung und Beschaffung der Erdoberfläche sind dabei wichtige Parameter.</p> <p>Typische Prozesse des Mesoklimas sind Fronten, Gewitter, tropische Stürme und großräumigere Wolkencluster. Beispielsweise können auch viele Phänomene des Stadtklimas (wie z.B. die Hitzeinsel) dem Mesoklima zugeordnet werden.“ [117]</p> |
| Mikroklima | „Das Mikroklima beschreibt mittlere atmosphärische Zustände und wiederkehrende Phänomene im mikrometeorologischen Maßstabsbereich. Nach Orlanski (1975) werden atmosphärische Prozesse mit einer horizontalen Ausdehnung von wenigen Millimetern bis einigen hundert Metern der Mikroskala zugeordnet. Mit Mikroklima ist damit das spezielle Klima eines Areals gemeint, das sich in den bodennahen Luftschichten ausbildet und stark von den vorhandenen Oberflächen (Untergrund, Bewuchs, Bebauung), z.B. deren Rauigkeit und thermischen Eigenschaften, beeinflusst ist. Verschiedenheiten in der Geländeform oder im Pflanzenbewuchs können dabei auf engem Raum große Unterschiede in der Temperatur oder der Windgeschwindigkeit verursachen. So kann es z.B. an einem Sommertag über einer Asphaltdecke mehrere Grad wärmer sein als über einer benachbarten, feuchten Wiese. Auch in klaren Nächten können sich, z.B. durch unterschiedliche Ausstrahlungsbedingungen, auf kleinem Raum signifikante Temperaturunterschiede ergeben.“ [117] |
| Regional-klima | „Der Begriff Regionalklima ist eng verwandt mit dem des Mesoklimas. Es sind dabei Phänomene mit sehr ähnlichen Raum- und Zeitskalen gemeint, die durch sowohl groß- als auch kleinskalige Prozesse beeinflusst werden, aber auch von regionalen Gegebenheiten wie der Geländeform und der Landnutzung abhängen. Beim Regionalklima, im Gegensatz zum Mesoklima, wird deutlicher der Bezug zu natur- oder kulturräumlichen Klimabesonderheiten hergestellt. Beispielsweise ist die Phänologie der Pflanzen ein guter Indikator für das Regionalklima einer Region.“ [117] |

Die Beziehungen zwischen den verschiedenen Klimata in der Tabelle 12 und den entsprechenden Skalen sind in der Abbildung 54 zur besseren Veranschaulichung dargestellt.




Abbildung 54: Räumliche und zeitliche Skalierung des Klimas mit Angabe der Klima-Art und der örtlichen Ausdehnung (Quelle: [118] S. 20 nach [119, 120])

Bei der Betrachtung der äußeren Umwelteinflüsse wird das Mikroklima weitgehend vernachlässigt und sich hauptsächlich auf Einflüsse konzentriert, die dem Mesoklima zuzuordnen sind. Die Erfassung der mikroklimatischen Verhältnisse an jedem einzelnen Standort stünde in keinem Verhältnis zum Aufwand.

Allgemein können unter den äußeren mesoklimatischen Umwelteinflüssen folgende Einflüsse aufgeführt werden, die sich positiv oder negativ auf die Bauteile auswirken und dadurch den Abbau des Abnutzungsvorrats verzögern oder beschleunigen [7, 11, 25]: Erschütterung, Feuchtigkeit, Luftverschmutzung, mechanische Belastung, Schnee, Strahlung, Temperatur und Wind. Jedem einzelnen Umwelteinfluss ist ein eigenständiges Unterkapitel gewidmet.

5.2.6.1 Erschütterung

Erschütterungen von Bauwerken können beträchtliche Schäden an Bauteilen verursachen und somit den Abbau des Abnutzungsvorrates signifikant beschleunigen. Das Schadensbild reicht je nach Intensität, Frequenzspektrum und der Erschütterungsart von Risschäden in der Bausubstanz bis hin zum Verlust der Tragfähigkeit eines Bauwerkes.


Ursachen für solche Erschütterungen können menschliche Aktivitäten wie beispielsweise Bauarbeiten, Bahnverkehr oder Schwerlastverkehr auf Straßen sein. Diese Aktivitäten können Schwingungen und Vibrationen erzeugen, die sich auf das Gebäude übertragen und zu Erschütterungen führen.

Weitere Ursachen für Erschütterungen sind natürliche Ereignisse wie Erdbeben, Stürme oder Setzungen durch Bergbau, Grundwasserabsenkungen oder geologische Randbedingungen, die sich negativ auf die Bausubstanz auswirken können.

Allgemein lässt sich sagen, dass Bauwerke gegen Erschütterungen relativ unempfindlich sind [121].

Lediglich bei außerordentlich starken Erschütterungen ist mit Schäden an der Tragfähigkeit eines Bauwerks zu rechnen [121]. Dennoch können bereits vorher Schäden wie Risse im Verputz oder Sprünge in Fensterscheiben auftreten.

Die Beurteilung der Erschütterungseinwirkungen erfolgt in Deutschland nach der DIN Norm 4150 Teil 3 [122]. Dort findet man Tabellen mit Anhaltswerten, ab welcher Frequenz kurzzeitige Erschütterungen bzw. Dauererschütterungen bei welcher Gebäudeart zu Schäden führen können.



Zur Veranschaulichung dient die Abbildung 55, in der zu erkennen ist, dass Erschütterungen, die für den Menschen als unangenehm oder belästigend empfunden werden, nicht zwingend schädliche Auswirkungen auf die Bausubstanz haben müssen.

Aus diesen Zahlen lässt sich ableiten, dass bezüglich von Erschütterungen lediglich Erdbeben eine ernste Gefahr für Bauwerke darstellen.

Abbildung 55: Allgemeine Grenzwerte der Wegamplitude für Erschütterungen (Quelle: [121] S. 1 nach [123])

Für die Quantifizierung der Stärke eines Erdbebens wird in Deutschland für gewöhnlich auf die Richterskala (Lokalbeben-Magnitude) zurückgegriffen. Die Richterskala oder M_L -Skala (Lokalbeben-Magnituden-Skala, M_L^{38}) reicht von $< 2,0 M_L$ bis $6,5 M_L$, die Richterskala ist messtechnisch auf 6,5 begrenzt. Bei Werten über 6,5 kommt die sogenannte Momenten-Magnituden-Skala (M_W^{39}) zum Einsatz, die Beben bis zu einer Stärke von $10,0 M_W$ abbilden kann. Die Werte der Momenten-Magnituden-Skala sind mit den Werten der Lokalbeben-Magnituden-Skala harmonisch.

Für die Prognose von durch Erdbeben erzeugte Erschütterungen wird in Deutschland auf die DIN EN 1998-1 [124] zurückgegriffen, die DIN 4149 [125] wurde in ihrer letzten Fassung (DIN 4149:2005-04) zurückgezogen und durch die DIN EN 1998-1 sowie DIN EN 1998-5 ersetzt.

³⁸ Das Formelzeichen leitet sich aus dem englischen „magnitude local“ ab.

³⁹ Das Formelzeichen leitet sich aus dem englischen „mechanical work“ ab.

In der DIN EN 1998-1/NA:2011-01 [126] (Nationaler Anhang zur DIN EN 1998-1) wurde für die seismische Einwirkung der „Referenz Spitzenwert der Bodenbeschleunigung“ (a_{gR}) in m/s^2 als Kenngröße verwendet. Diese Werte sind den Intensitätsintervallen der Erdbebenzonen zugeordnet [127].

Seit dem Entwurf der DIN EN 1998-1/NA:2018-10 [128] wird stattdessen als Kenngröße der Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R}$ in m/s^2 verwendet.

Ein Antwortspektrum berechnet sich aus der Bodenbeschleunigung und der lokalen Baugrund- und Untergrundklasse. Diese Werte sind keinen Intensitätsintervallen zugeordnet.

Im Gegensatz zur DIN EN 1998-1/NA:2011-01 werden damit in der DIN EN 1998-1/NA:2018-10 epistemische⁴⁰ Ungewissheiten bei der Berechnung berücksichtigt [129].

In der Abbildung 56 sind die Erdbebenzonen nach DIN EN 1998-1/NA:2021-07 illustriert.




Abbildung 56: Erdbebenzonen in Deutschland nach der DIN EN 1998-1/NA:2021-07 - mittlere Wiederkehrperiode von 475 Jahren (Dlubal Geo-Zonen-Tool für Lastermittlung) (Quelle: modifizierte Darstellung nach [130])

⁴⁰ Aufgrund einer mangelhaften Datenbasis.

Ab $1,3 M_L$ ist die Spürbarkeitsgrenze für den Menschen etwa erreicht, ab $2,7 M_L$ können Schäden an empfindlichen Gebäuden, wie Fachwerkhäusern, auftreten [122, 131].

5.2.6.2 Feuchtigkeit

Ein weiterer Einflussfaktor auf die Lebensdauern von Bauteilen ist Feuchtigkeit, die in Form von Niederschlägen wie Regen, Eisregen, Schnee oder Hagel oder in Form von beispielsweise Grundwasser auftreten kann.

Feuchtigkeit kann insbesondere in Kombination mit Minustemperaturen zu enormen Schäden an der Bausubstanz führen, ebenso können durch Feuchtigkeit biologische Prozesse in Gang gesetzt werden, die die Ansiedlung von Ungeziefer, Pflanzen oder Pilzen begünstigen. In welchem Ausmaß die Feuchtigkeit den Abbau des Abnutzungsvorrates beschleunigt, ist dabei von dem entsprechenden Material des zu betrachtenden Bauelements abhängig.

Im weiteren Verlauf dieser Arbeit wird die Feuchtigkeit in Form von Grundwasser als Sonderfall betrachtet und daher vernachlässigt, es folgt daher ausschließlich eine Erläuterung zum Thema Niederschlag. Für die Prognose und Bewertung der Beanspruchung durch Niederschlag kann entweder auf Kartierungen, ähnlich wie in Kapitel 5.2.6.1, zurückgegriffen werden, in denen sogenannte Beanspruchungs- oder Risikogruppen verzeichnet sind, oder auf konkrete Wetterdaten der jeweiligen Standorte.

Die in der Literatur für gewöhnlich verwendete Kartierung, wie auch bei Bahr und Lennerts [11], ist die Übersichtskarte zur Schlagregenbeanspruchung der DIN 4108-3 [132].




Abbildung 57: Übersichtskarte zur Schlagregenbeanspruchung in der Bundesrepublik Deutschland nach den Daten des Deutschen Wetterdienstes (Quelle: [132] S. 37)

Die DIN 4108-3 differenziert zwischen drei Beanspruchungsgruppen:

Beanspruchungsgruppe I: Jahresniederschlagsmenge < 600 mm, gilt auch für größere Niederschlagsmengen bei besonders windgeschützter Lage [132].

Beanspruchungsgruppe II: Jahresniederschlagsmenge zwischen 600 mm und 800 mm, gilt auch für größere Niederschlagsmengen bei besonders windgeschützter Lage, gilt auch für Hochhäuser sowie für Häuser in exponierter Lage, die ansonsten in Gruppe I wären [132].

Beanspruchungsgruppe III: Jahresniederschlagsmenge > 800mm, gilt auch bei geringeren Niederschlagsmengen in windreichen Gebieten, gilt auch für Hochhäuser sowie für Häuser in exponierter Lage, die ansonsten in Gruppe II wären [132].

Aufgrund der Verfügbarkeit historischer Wetterdaten über die Datenbank des Deutschen Wetterdienstes wurde für diese Arbeit die Entscheidung getroffen, anstelle der Einteilung in drei Gruppen die sehr detaillierten Wetterdaten des Deutschen Wetterdienstes für das Trainings des künstlich neuronalen Netzwerkes zu verwenden (vgl. 9.3). Diese Entscheidung wurde getroffen, da die verfügbaren hochaufgelösten Daten des Deutschen Wetterdienstes für das in dieser Arbeit angestrebte Training als geeigneter angesehen werden als die sehr grobe Einteilung in drei Gruppen.

5.2.6.3 Hagel

Obwohl Hagel der übergeordneten Kategorie Niederschlag zugeordnet ist und somit über die meteorologischen Daten des Niederschlags bereits erfasst wird, ist es notwendig, das Thema Hagel nochmals gesondert zu betrachten.

Der Grund dafür ist, dass Hagel aufgrund seiner kinetischen Energie in der Lage ist, erhebliche Schäden, neben den Auswirkungen durch die Feuchtigkeit, zu verursachen.

Für die Messung von Hagel gibt es keine Sensoren, wie für Regen oder Wind, daher kartiert der Deutsche Wetterdienst Hagelereignisse ausschließlich auf der Grundlage von Beobachtungen und Schätzungen. Gemäß dem Deutschen Wetterdienst ist die Datenbasis zur Beobachtung von Hagelschlägen sehr unzureichend und objektive Auswertungen können auch durch Schätzungen nicht garantiert werden [133].

Um Hagelereignisse dennoch zumindest näherungsweise berücksichtigen zu können, kann auf Daten der Versicherungen zurückgegriffen werden. Die Versicherungen dokumentieren jeden einzelnen Hagelschaden sehr genau und teilen auf dieser Datenbasis Deutschland in verschiedene Risikozonen ein, um die Versicherungsnehmer nach dem örtlichen Risiko für eine Versicherung gegen Hagelschäden einstufen zu können.

Diese internen Informationen der Versicherungen sind jedoch für Außenstehende in der Regel nicht zugänglich. Eine der wenigen auffindbaren Karten stammt von der Münchener Rück aus dem Jahr 2009 (vgl. Abbildung 58). Ebenso existiert eine Karte für das Hagelrisiko nach Schadensätzen (1980 - 1998) (vgl. Abbildung 59) aus der Dissertation von Ritter [7], die auf der Internetseite von Bayer CropScience zu finden war, aber nicht mehr abrufbar ist (12/2023).




Abbildung 58: Hagelzonen nach Münchener Rück 2009 (Quelle: [134] S. 64 nach [135])




Abbildung 59: Hagelschlagrisiko 1980 - 1998 nach Schadensätzen (Quelle: [7] S. 218 nach [136])

Die beiden Karten sind im Anhang in der Originalgröße enthalten (vgl. Anhang A 5, Anhang A 6). Obwohl die verfügbaren Daten begrenzt sind, lassen sie gewisse Hinweise auf das Hagelrisiko in verschiedenen Regionen zu.


5.2.6.4 Luftverschmutzung

Ein weiterer Faktor, der sich auf die Lebensdauer von Bauteilen auswirkt, ist die Luftverschmutzung durch Schadstoffe. Nach heutigem Kenntnisstand wirken sich vor allem

Kohlenstoffdioxid (CO_2)⁴¹, Ozon (O_3), Schwefeldioxid (SO_2), Stickoxide (NO_x) und partikelförmige Luftverunreinigungen in Form von Staub und Ruß schädigend auf die Bausubstanz aus.

Die Auswirkungen von abgelagerten Schadstoffen auf Bauteiloberflächen sind abhängig von dem jeweiligen Baustoff. Bei mineralischen Baustoffen können abgelagerte Schadstoffe zu Auflösungen und Auswaschungen führen, die Abplatzungen und damit Schäden an der Bausubstanz zur Folge haben können. Bei Metallen können Schadstoffe den Korrosionsprozess beschleunigen, was ebenfalls Schäden an den betroffenen Bauteilen auslösen kann [11]. Bei Beton kann die Karbonatisierung durch Schadstoffe beschleunigt werden, was zu einer Bewehrungskorrosion führen kann, wodurch schwerwiegende Schäden entstehen können.

Für die Beurteilung der Luftverschmutzung gibt es, wie für Niederschlag oder Hagel, Kartierungen mit Angaben zur jeweiligen Schadstoffbelastung [11]. Das Umweltbundesamt stellt dafür eine Webanwendung zur Verfügung, in der die Luftdaten aller Messstationen der Bundesländer abgerufen werden können.



Aufgrund der geringen Dichte an Messstationen und der Beschränkung vieler Messstellen auf den Schadstoff Feinstaub sind Werte für die oben aufgeführten Schadstoffe fast ausschließlich nur für Großstädte verfügbar.

Am Beispiel der Messstationen für Schwefeldioxid ist die Dichte der Stationen in der Abbildung 60 verdeutlicht, die unterschiedlichen Farben sind dabei nicht relevant.

Abbildung 60: Luftdaten des Umweltbundesamtes nach Stationen (Quelle: [137])

Bedingt durch die ungenügende Datengrundlage bezüglich der erwähnten Schadstoffe, wird das Thema Schadstoffe bei der Entwicklung der Methode nicht weiter berücksichtigt.

5.2.6.5 Schnee

Neben der Wirkung des Schnees durch seine Feuchtigkeit kann Schnee auch durch sein Gewicht (Schneelast) direkt auf einzelne Bauteile eines Gebäudes, insbesondere auf das Dach, negativ einwirken. Daher wird in diesem Kapitel noch einmal gesondert auf Schnee als Einflussfaktor eingegangen.

Die regionalen Schneelasten auf dem Boden (Schneelastzonen) werden in Deutschland auf der Grundlage des Nationalen Anhanges DIN EN 1991-1-3/NA [138] der DIN EN 1991-1-3

⁴¹ Kohlenstoffdioxid ist zu 0,029 Vol. % ein natürlicher Bestandteil der Atmosphäre, erst bei einem Überschreiten dieses Grenzwertes kann Kohlenstoffdioxid als Schadstoff betrachtet werden.

[139] ermittelt. Diese Norm illustriert dabei in einer Karte die Schneelastzonen: Zone 1, Zone 1a, Zone 2, Zone 2a und Zone 3. Die Norm merkt an, dass für die Schneelastzonen 1 und 2 in der Norddeutschen Tiefebene sowie für einige Gebiete in der Schneelastzone 3 höhere Schneelastwerte auftreten können als in der DIN EN 1991-1-3/NA [138] angegeben. Die DIN verweist an dieser Stelle auf die Tabelle „Zuordnung der Schneelastzonen nach Verwaltungsgrenzen“ des Deutschen Institutes für Bautechnik (DIBt). In dieser Tabelle des DIBt finden sich für jeden Landkreis entsprechende Zuordnungen und Hinweise, welche eventuellen zusätzlichen Bestimmungen zu beachten sind. So wird beispielsweise bei den Schneelastzonen von Mecklenburg-Vorpommern auf die Berücksichtigung der „Bestimmungen der Anlage A 1.2.1/4 der Verwaltungsvorschrift Technische Baubestimmungen Mecklenburg-Vorpommern (VV TB M-V) gem. Erlass des Ministeriums für Inneres, Bau und Digitalisierung vom 05. Januar 2023 - II-516-00000-2022/015 - zu beachten“ verwiesen.

Eine grafische Aufbereitung dieser Karte (vgl. Abbildung 61) einschließlich der Randbedingungen wie z.B. die „Einteilung der Schneelastzonen nach Verwaltungsgrenzen des Deutschen Institutes für Bautechnik (DIBt)“ [140], der „Liste der Technischen Baubestimmungen Mecklenburg-Vorpommern“ [141] sowie der Ergebnisse des Gutachtens „Flächenhafte Analyse von Schneelastmesswerten in fünf Landkreisen und ihr Vergleich mit den Schneelastzonendaten der DIN 1055-5:2005 als Pilotuntersuchung für die Überarbeitung der Schneelastzonenkarte“ des [142] des Deutschen Wetterdienstes findet sich im Geo-Zonen-Tool zur Lastermittlung der Firma Dlubal Software GmbH.

Zur Abbildung der verschiedenen Sonderbedingungen werden die ursprünglichen Zonen auf Zone 1, Zone 1*, Zone 1a, Zone 1a*, Zone 2, Zone 2a, Zone 3, Zone 3*, Zone 3a und Zone >3a erweitert.

**Erweiterte
Schneelastzonen
auf Basis der DIN
EN 1991-1-
3/NA:2019-04**





Abbildung 61: Erweiterte Schneelastzonen in Deutschland nach der DIN EN 1991-1-3/NA (Diubal Geo-Zonen-Tool für Lastermittlung) (Quelle: modifizierte Darstellung nach [130] nach [138, 141, 142])

5.2.6.6 Strahlung

Die Sonnenstrahlung, die als Solarenergie auf die Erdoberfläche trifft, ist in verschiedene Spektralbereiche unterteilt. Ein großer Teil dieser Energie wird von der Erdatmosphäre absorbiert oder gestreut. Wie groß dieser Anteil genau ist, hängt von verschiedenen Faktoren wie dem Sonnenstand, dem Spektralbereich und den meteorologischen Bedingungen ab [7].

Das Sonnenspektrum unterteilt sich in ultraviolettes Licht (UV) von 100 bis 380 nm, das sichtbare Licht (VIS) von 380 bis 780 nm und infrarotes Licht (IR) von 780 nm bis 1 mm.

Aufgrund der kleinsten Wellenlänge im Spektrum ist die UV-Strahlung auch die energiereichste Strahlung, denn nach Albert Einstein gilt, dass die Energie eines Photons sich aus dem Produkt aus dem Plancksche Wirkungsquantum h ($= 6,626 \times 10^{-34} \text{ J s}$) und der Frequenz f ergibt (vgl. Formel 5.1). Da die Wellenlänge λ der Division der Lichtgeschwindigkeit c

(= $2,998 \times 10^8 \text{ m/s}$) durch die Frequenz entspricht (vgl. Formel 5.2), lässt sich die Energie eines Photons, wie in der Formel 5.3 dargestellt, berechnen.

(Quelle: [143])
$$E_{ph} = h \times f \quad 5.1$$

(Quelle: [143])
$$\lambda = \frac{c}{f} \quad 5.2$$

(Quelle: [143])
$$E_{ph} = \frac{h \times c}{\lambda} \quad 5.3$$

Die UV-Strahlung ist als energiereichste Strahlung auch die schädlichste für Gebäude.

UV-Strahlung kann Holzfasern schädigen, kann molekularen Strukturen im Beton aufbrechen und schwächen oder zu Sprödigkeit an Kunststoffen führen. Baustoffe wie Metall sind hingegen gegen UV-Strahlung nahezu unempfindlich.

Daher werden außenliegende Holzelemente für gewöhnlich mit einem UV-resistenten Schutzanstrich versehen, Beton werden Polymere⁴² [144, 145] oder andere Schutzstoffe beigemischt und Mauerwerk wird mit einem Putz versehen, der Komponenten enthält, die vor der schädlichen UV-Strahlung schützen.

Die Schädigung durch UV-Strahlung an Baustoffen geht in die meisten Fällen mit einer Verfärbung der Oberfläche einher.

Für die Berücksichtigung der Sonnenstrahlung wird in dieser Arbeit auf die Datensätze zur Sonnenscheindauer des Deutschen Wetterdienstes zurückgegriffen, da die Sonnenscheindauer sehr stark mit der Globalstrahlung korreliert (vgl. Abbildung 62, Abbildung 63) und Werte zur lokalen Sonnenscheindauer wesentlich einfacher zugänglich sind.

⁴² Polymerbeton ist eine Betonvariante, bei der ein Polymer als Bindemittel anstelle von kalkhaltigem Zement verwendet wird bzw. in einem Mix mit Portlandzement [144, 145].




Abbildung 62: Jahresmittel 2011 - 2020 Globalstrahlung [kWh/m²]

(Quelle: [146] S. 6)




Abbildung 63: Sonnenscheindauer im Jahresmittel 2019 Deutschland [h]

(Quelle: [147] S. 7)

5.2.6.7 Temperatur

Ein weiterer Einflussfaktor auf den Abnutzungsvorrat der Bauteile von Gebäuden ist die Temperatur. Dabei spielt neben der Durchschnittstemperatur auch die Minimaltemperatur, die Maximaltemperatur sowie die Amplitude zwischen den Maximalwerten und den Minimalwerten eine große Rolle. So können neben Extremtemperaturen auch große Temperaturschwankungen zu Schäden am Gebäude führen.

Eine große Temperaturdifferenz innerhalb eines Tages, auch als tägliche Temperaturschwankung bezeichnet, ist in Deutschland aufgrund der eher geringen täglichen Schwankung der Temperatur vernachlässigbar. Allerdings können auch Temperaturschwankungen aufgrund von jahreszeitlichen Klimaänderungen durchaus negative Auswirkungen auf Bauteile haben. In Kombination mit Feuchtigkeit können hohe Temperaturen den Trocknungsprozess beschleunigen und die Feuchtigkeit schneller aus dem Bauteil entziehen, während negative Temperaturen zu einer Volumenvergrößerung beim Wechsel des Aggregatzustandes von Wasser zu Eis führen, was zu sogenannten Frostsprengungen des Materials führen kann.

Die langjährigen Mittelwerte der Lufttemperatur, die mittleren Tageshöchst- und -tiefsttemperaturen, die langjährigen Mittelwerte der Eistage⁴³ sowie die langjährigen Mittelwerte der Frosttage⁴⁴ sind für die meisten Messstationen auf der Homepage des Deutschen Wetterdienstes frei verfügbar.

In Kombination mit den Feuchtigkeitsdaten kann das neuronale Modell, welches in Kapitel 9.1 und Kapitel 9.3 entwickelt wird, u.a. erlernen, wie sich spezifische Kombinationen aus Feuchtigkeit und Temperatur auf die Lebensdauer bestimmter Bauteile auswirken.

5.2.6.8 Wind

Windlasten können erhebliche Auswirkungen auf die Abnutzungsvorräte von Bauteilen haben, insbesondere bei hohen oder exponierten Bauwerken. Bei entsprechend hohen Windgeschwindigkeiten bzw. Winddrücken können Materialien in Schwingung versetzt werden, wodurch z.B. Fenster zerbrechen oder Dächer abgedeckt werden. Bei Flachdächern können Windverfrachtungen der Kiesschicht zu einem beschleunigten Verschleiß der Flachdachabdichtung führen.

Eine fehlerhafte Berücksichtigung der Windlast in der Statik kann im Extremfall zum Einsturz hoher Bauwerke führen. Ebenso können bei fehlerhafter Planung übermäßige Schwingungen zur Zerstörung eines Bauwerks führen (Resonanzkatastrophe). Eine Resonanzkatastrophe liegt vor, wenn die Resonanzfrequenz eines Bauteils mit einer externen Anregungsfrequenz übereinstimmt und es dadurch zu einer unkontrollierten Verstärkung der Schwingung kommt.

Deutschland ist nach der DIN EN 1991-1-4/NA [148] (Nationalen Anhang zur DIN EN 1991-1-4 [149]) in vier Windzonen eingeteilt: WZ 1, WZ 2, WZ 3 und WZ 4. Wie auch das Deutsche Institut für Bautechnik (DIBt) [140] eine „Einteilung der Schneelastzonen nach Verwaltungsgrenzen“ [140] zur Verfügung stellt, bietet das DIBt auch eine „Einteilung der Windlastzonen nach Verwaltungsgrenzen“ [140] an.

Auf diese wird in DIN EN 1991-1-4/NA jedoch nicht explizit verwiesen, wie dies bei DIN EN 1991-1-3/NA der Fall ist.

Wie in der Tabelle der Schneelastzonen wird auch in der Tabelle der Windlastzonen auf zusätzlich zu berücksichtigende Sonderbestimmungen hingewiesen. Für den Bereich des Hamburger Hafens wird z.B. auf die Technischen Baubestimmungen der Stadt Hamburg verwiesen.


Die aktuelle Fassung der 1991-1-4/NA ist die DIN EN 1991-1-4/NA:2010-12 [148].

In der Abbildung 64 sind die Windzonen nach DIN EN 1991-1-4/NA:2010-12 für den Leser illustriert.

⁴³ Tage mit Tagesmaximum der Temperatur < 0 °C.

⁴⁴ Tage mit Tagesminimum der Temperatur < 0 °C.

Erweiterte Windlastzonen auf Basis der DIN EN 1991-1-4/NA:2010-12



*besondere Anforderungen im Gebiet des Hamburger Hafens nach der Technischen Baubestimmungen der Stadt Hamburg [150]



Abbildung 64: Erweiterte Windzonen in Deutschland nach der DIN EN 1991-1-4/NA:2010-12 (Dlubal Geo-Zonen-Tool für Lastermittlung) (Quelle: modifizierte Darstellung nach [130] nach [140, 148, 150])

5.2.7 Nutzungszustand

Die Lebensdauern von Gebäuden werden maßgeblich durch die Nutzung beeinflusst, insbesondere die Bauteile des Innenausbaus wie Böden, Fenster, Türen und Wände. Die Intensität der Beanspruchung und die Art der möglichen Belastungen hängen direkt von der Art der Gebäudenutzung ab. Der Nutzungszustand wird in der Faktorenmethode nach der ISO 15686 unter dem Faktor F (vgl. Tabelle 5) berücksichtigt.

So sind beispielsweise Bauteile in Schulen, Krankenhäusern oder Einzelhandelsimmobilien für gewöhnlich höheren Belastungen ausgesetzt als solche in Altenheimen. Auch die Anzahl der Personen, die das Gebäude nutzen, die zur Verfügung stehende Fläche und die Dauer der Nutzung beeinflussen den Abnutzungsprozess der Bauteile. Je nach Stärke der Beanspruchung kann ein Bauteil kürzer oder länger halten [11].

Das Nutzerverhalten trägt somit wesentlich zur Abnutzung von Gebäuden, insbesondere von Bauteilen des Innenausbaus, bei.

Kalusche [151] schreibt „Im günstigsten Fall pflegt der Nutzer das Gebäude mit der erforderlichen Sorgfalt selbst. Im ungünstigsten Fall werden Teile des Gebäudes in kürzester Zeit durch Vandalismus zerstört.“ [151] (S. 3).

Bahr und Lennerts [11] ergänzen die Aussage von Kalusche folgendermaßen: „Ausschlaggebend für das Nutzerverhalten ist vor allem der Grad der Identifikation eines Nutzers mit dem Gebäude“ [11] (S. 36).

Als Beispiel für einen geringen Grad an Identifikation führen Bahr und Lennerts [11] die Gemeinschaftsbereiche von großen Wohnanlagen auf.

Im Gegensatz dazu fördern Gebäude, deren Bewohner sich kennen, die Eigenverantwortung. So werden dort kleinere Instandhaltungsmaßnahmen teilweise in Eigeninitiative durchgeführt, was sich positiv auf die Lebensdauern der Bauteile auswirkt [152].

Laut IPBAU [55] sind die Lebensdauern von Bauteilen in Büros durchschnittlich um 20 % geringer als bei privat genutzten Gebäuden. In Restaurants ist die Lebensdauer sogar durchschnittlich um 50 % geringer als bei privater Nutzung [55].

5.2.8 Instandhaltungsqualität

Die Qualität der Instandhaltung, Faktor G in der Faktorenmethode nach der ISO 15686 (vgl. Tabelle 5), hat einen erheblichen Einfluss auf die Lebensdauer von Bauteilen. Eine schlechte Instandhaltungsqualität kann die Lebensdauer von Bauteilen verkürzen, während eine gute Instandhaltungsqualität dazu beitragen kann, die Lebensdauer von Bauteilen zu verlängern.

Eine qualitativ hochwertige Instandhaltung erfordert regelmäßige, fachgerechte Inspektionen und Wartungen. Je nach Art des Bauteils können auch Reinigungs- oder Schmierarbeiten erforderlich sein.

Eine unzureichende Instandhaltungsqualität kann zu einem beschleunigten Verschleiß von Bauteilen führen und somit ihre Lebensdauer erheblich verkürzen. Eine hochwertige Instandhaltung kann zudem den Einsatz spezialisierter Techniken wie Ultraschallprüfung oder Thermografie sowie die Verwendung hochwertiger Ersatzteile und Materialien umfassen.

Eine hohe Instandhaltungsqualität (Wartung, Inspektion, Instandsetzung, Verbesserung) kann dazu beitragen, den Abbau des Abnutzungsvorrats zu verzögern. Im Gegensatz dazu können eine niedrige Qualität oder das Fehlen von Instandhaltung zu einem beschleunigten Abbau des Abnutzungsvorrats führen (vgl. Abbildung 65).




Abbildung 65: Auswirkung der Instandhaltungsqualität auf den Abbau des Abnutzungsvorrates (Quelle: eigene Darstellung)

5.3 Immaterielle Einflussfaktoren

Neben den materiellen Einflussfaktoren gibt es auch so genannte immaterielle Faktoren, die die Lebensdauer von Bauteilen beeinflussen können. So hängt die Nutzung eines Bauteils nicht nur von seiner technischen Lebensdauer ab, sondern auch von weiteren Randbedingungen.

Es gibt verschiedene Gründe, warum Bauteile in einem Gebäude trotz Funktionstüchtigkeit ausgetauscht werden. Einer der Gründe hierfür sind modische Aspekte, die der Grund für den Austausch eines Bauteils sein können, obwohl es noch funktionsfähig ist und seine technische Lebensdauer noch nicht erreicht hat.

Ein weiterer Faktor ist der technologische Fortschritt, der dazu führen kann, dass ein Bauteil durch ein neueres und effizienteres Bauteil ersetzt wird. Auch normative Änderungen wie beispielsweise die Einführung neuer DIN-Normen können den Austausch von Komponenten erforderlich machen, selbst wenn diese noch voll funktionsfähig sind.

Immaterielle Faktoren können die theoretische Lebensdauer eines Bauteils reduzieren mit der Folge, dass das Bauteil ersetzt wird, bevor seine technische Lebensdauer erschöpft ist. Die "immaterielle Alterung" ist nicht vom Bauteil selbst abhängig und somit nicht beeinflussbar. Das erschwert die Vorhersage der tatsächlichen Lebensdauer von Bauteilen und die Planung von Ersatzmaßnahmen. Dennoch ist es wichtig, die immateriellen Faktoren bei der Planung von Bauprojekten zu berücksichtigen, um eine möglichst lange Lebensdauer und eine nachhaltige Ressourcennutzung der Bauteile zu gewährleisten [11, 39].

Eine Auflistung möglicher immaterieller Einflussfaktoren finden Sie in der Tabelle 13. Diese basieren auf den Forschungsergebnisse von Ritter [7] sowie Bahr und Lennerts [11].

Tabelle 13: Immaterielle Einflussfaktoren (Quelle: eigene Darstellung nach [11] S. 41 ff. und [7] S. 93 ff.)

| | |
|----------------------|---|
| Modische Faktoren | Ästhetische Gründe können dazu führen, dass ein Bauteil aufgrund seiner Farbe, Struktur oder Form vorzeitig ausgetauscht wird. |
| Rechtliche Faktoren | Bei Änderungen von Normen oder Richtlinien kann es zu einem Austausch funktionstüchtiger Bauteile kommen. |
| Ökologische Faktoren | Ändern sich beispielsweise die Ansprüche an die Energieeffizienz eines Gebäudes, kann das dazu führen, dass einzelne Bauelemente ausgetauscht werden, obwohl der Abnutzungsvorrat noch nicht aufgebraucht ist. |
| Ökonomische Faktoren | Können die Nutzungskosten eines Gebäudes durch den Austausch spezifischer Bauteile reduziert werden, spricht man von einem Austausch aufgrund ökonomischer Faktoren. Ein Beispiel wäre der Austausch der Heizung, mit dem Ziel die Heizkosten zu senken. |
| Technische Faktoren | Entspricht ein Bauteil nicht dem aktuellen technischen Standard, kann auch das zu einem vorzeitigen Austausch führen, obwohl das Element frei von Mängeln ist. Ein Beispiel wäre hier der Austausch von Schließzylindern, wenn diese nicht mehr den entsprechenden Sicherheitsanforderung gerecht werden. |

Hinweise: Die Tabelle 13 erhebt keinen Anspruch auf Vollständigkeit und stellt nur die in der Praxis häufig anzutreffenden Einflussfaktoren dar. Darüber hinaus gibt es eine Vielzahl weiterer Faktoren, die in der Tabelle nicht aufgeführt sind. So definiert Schwaiger [153] (S. 68) in ihrer Dissertation u.a. die Bevölkerungsentwicklung und den Strukturwandel als (immaterielle) Einflussfaktoren.

6 Auswahl der Bauteile (Gebäudehülle)

Die vorliegende Arbeit beschränkt sich bei der Betrachtung der Bauteile auf die Elemente der äußeren Gebäudehülle.

Das wird damit begründet, dass bedingt durch die Begrenzung der Einflussfaktoren auf die äußeren Umwelteinflüsse, angenommen wird, dass die Auswirkungen der Einflussfaktoren (vgl. Kapitel 5) auf die außenliegenden Bauteile am signifikantesten sind.

Bei der Auswahl wurde außerdem berücksichtigt, dass ausschließlich Bauelemente ausgewählt wurden, bei denen eine ausreichende⁴⁵ Anzahl an Datensätzen vorliegt.

Somit wurde beispielsweise die Kostengruppe 332(0) (Nichttragende Außenwände) oder die Kostengruppe 333(0) (Außenstützen) aufgrund fehlender Datensätze im Vorhinein entfernt und nicht weiter berücksichtigt.

Somit gelten für die Gruppierung der relevanten Bauelemente folgende Kriterien:

- Bestandteil der äußeren Gebäudehülle,
- Ausreichende Menge an Datensätzen vorhanden.

Eine Auflistung der Auswahl der relevanten Bauelemente kann der Tabelle 14 entnommen werden.

Mit der KG 3632 und der KG 3631 werden Flachdächer sowie Steildächer betrachtet.

Tabelle 14: Relevante Bauelemente (Quelle: eigene Darstellung)

| KG | Bezeichnung |
|---------|------------------------------------|
| KG 3310 | Tragende Außenwände |
| KG 3341 | Außenwandöffnung: Außenfenster |
| KG 3342 | Außenwandöffnung: Außentüren |
| KG 3351 | Außenwandbekleidungen, außen: Putz |
| KG 3620 | Dachöffnungen |
| KG 3631 | Dachbeläge: Flachdachabdichtung |
| KG 3632 | Dachbeläge: Dachdeckung |
| KG 3633 | Dachbeläge: Attikaabdeckung |
| KG 3634 | Dachbeläge: Entwässerung |

Die Analyse der äußeren Gebäudehülle ermöglicht eine gezielte Untersuchung der Bauteile, die besonders stark von den äußeren Umwelteinflüssen betroffen sind.

Die äußere Gebäudehülle schützt den Innenraum vor Witterungseinflüssen wie beispielsweise Regen, Wind, Temperaturschwankungen und UV-Strahlung. Diese Einflüsse können die

⁴⁵ Weitere Informationen und die Definition der Schwellenwerte befinden sich in Kapitel 8.

Langlebigkeit, Stabilität und energetische Effizienz des Gebäudes maßgeblich beeinflussen. Daher sind sie von hoher Relevanz für die Vermeidung von zusätzlichen Instandhaltungskosten.

Obwohl die 4. Ebene ergänzt wurde, geht aus dieser Ebene nicht hervor, welches Material für das Bauteil verwendet wurde. Das bedeutet, dass Bauteile verschiedener Materialien auf dieser Ebene zusammengefasst werden. Um diese Zusammenfassung zu vermeiden, hätte man eine 5. Ebene mit Materialien definieren können.

Aufgrund der begrenzten Anzahl relevanter Bauteile werden jedoch für diese Arbeit nur die vergleichbaren Materialien der Bauteilauswahl definiert, um spätere Verzerrungen der Lebensdauern durch Materialmischungen auszuschließen.

Eine Auflistung der vergleichbaren Materialien befindet sich in der Tabelle 15.

Tabelle 15: Vergleichbarkeit der Datensätze (Quelle: eigene Darstellung)

| Kostengruppe (Bauelement) | nicht vergleichbar | vergleichbar |
|-------------------------------------|--|---|
| 3310 Tragende Außenwände | <ul style="list-style-type: none"> ▪ Außenwände, die durch Vandalismus Schaden getragen haben. ▪ Holzwände ▪ Mauerwerkswand ▪ Porenbetonsteine ▪ Sandsteinwände ▪ Stahlbauwand ▪ Unbekleidete Außenwände (Sichtbeton) | <ul style="list-style-type: none"> ▪ Betonwand (Betonfertigbauteile, Ortbeton) |
| 3341 Außenwandöffnung: Außenfenster | <ul style="list-style-type: none"> ▪ Außenfenster, die durch Vandalismus Schaden getragen haben. ▪ Holzfenster ▪ Metallfenster | <ul style="list-style-type: none"> ▪ Kunststofffenster |
| 3342 Außenwandöffnung: Außentüren | <ul style="list-style-type: none"> ▪ Außentüren, die durch Vandalismus Schaden getragen haben. ▪ Brandschutztüren ▪ Drehtüren ▪ Glastüren ▪ Holztüren (Holzwerkstoff) ▪ Kunststofftüren | <ul style="list-style-type: none"> ▪ Holztüren (Laubholz, Nadelholz) |

| | | |
|---|---|--|
| | <ul style="list-style-type: none"> ▪ Metalltüren ▪ Schiebetüren ▪ Überdachte Türen | |
| 3370 Elementierte Außenwandkonstruktionen | <ul style="list-style-type: none"> ▪ Elementierte Außenwandkonstruktionen, die durch Vandalismus Schaden getragen haben. ▪ Betonfertigbauteile | <ul style="list-style-type: none"> ▪ Außenwandkonstruktionen aus Aluminium/Glas |
| 3351 Außenwandbekleidungen, außen: Putz | <ul style="list-style-type: none"> ▪ Putz, der durch Vandalismus Schaden getragen hat. | <ul style="list-style-type: none"> ▪ Putz (organisch, mineralisch) |
| 3620 Dachöffnungen | <ul style="list-style-type: none"> ▪ Dachausstiege ▪ Dachfenster (Holz) ▪ Dachfenster (Kunststoff) ▪ Oberlichter ▪ RWA⁴⁶ | <ul style="list-style-type: none"> ▪ Dachfenster (Aluminium) |
| 3631 Dachbeläge: Flachdachabdichtung | <ul style="list-style-type: none"> ▪ Flachdachabdichtung (Flüssigabdichtung) ▪ Flachdachabdichtung mit Bekiesung ▪ Flachdachabdichtung mit Dachbegrünung | <ul style="list-style-type: none"> ▪ Flachdachabdichtung (Bitumenbahnen, Elastomerbahnen, Kunststoffbahnen) |
| 3632 Dachbeläge: Dachdeckung | <ul style="list-style-type: none"> ▪ Dachdeckung: Beton ▪ Dachdeckung: Bitumenschindeln ▪ Dachdeckung: Glas ▪ Dachdeckung: Metall ▪ Dachdeckung: Reet ▪ Dachdeckung: Schiefer | <ul style="list-style-type: none"> ▪ Dachdeckung: Ziegel (Ton) |
| 3633 Dachbeläge: Attikaabdeckung | <ul style="list-style-type: none"> ▪ Dachdeckung (Betonfertigteil) | <ul style="list-style-type: none"> ▪ Attikaabdeckung (Aluminium, Edelstahl, Stahl) |

⁴⁶ Rauch- und Wärmeabzugsanlage.

| | | |
|----------------------------------|--|--|
| | <ul style="list-style-type: none">▪ Dachdeckung (Kunststoff)▪ Dachdeckung (Naturstein) | verzinkt) |
| 3634 Dachbeläge: Entwässerung | <ul style="list-style-type: none">▪ Entwässerung: Dachrin- nen, Regenfallrohre, Dachabläufe (Kunststoff) | <ul style="list-style-type: none">▪ Entwässerung: Dachrin- nen, Regenfallrohre, Dachabläufe (Stahl, Kup- fer, Zink, Aluminium) |

Die nicht vergleichbaren Datensätze wurden in der Phase der Datenaufbereitung entfernt (vgl. 8.2)

7 Auswahl der Orte

7.1 Einleitung

Für die Standortauswahl wurden innerhalb der Datenbasis der Software *dysisko* (vgl. Kapitel 8.1) Städte identifiziert, die möglichst vergleichbar waren. Der Prozess hatte zum Ziel, eine hohe Vergleichbarkeit sicherzustellen. Es wird angenommen, dass Großstädte aufgrund ihrer ökonomischen Bedingungen Instandhaltungsmaßnahmen in unterschiedlichen Qualitätsstufen vorantreiben als Kleinstädte. Basierend auf den Gegebenheiten der Datenbasis der Software *dysisko* wurde die Auswahl auf Mittelstädte⁴⁷ beschränkt.

Eine weitere Voraussetzung war, dass für die ausgewählten Standorte genügend Datensätze für alle Bauteile der Gebäudehülle vorhanden waren. Dies wurde im Nachgang bei der Datenaufbereitung (vgl. Kapitel 8.2) evaluiert. Eine detaillierte Auseinandersetzung mit der Datengrundlage wird gesondert in Kapitel 8 behandelt.

Während des Forschungsprozesses wurde die Auswahl der Untersuchungsstandorte (Kommunen) iterativ modifiziert. Schließlich wurde eine Bewertung der Datenbasis vorgenommen, wobei vier Standorte als quantitativ und qualitativ geeignet eingestuft wurden. Aus Gründen des Datenschutzes wird in dieser Arbeit auf eine explizite Nennung der einzelnen Kommunen verzichtet.

Infolgedessen werden die einzelnen Kommunen in dieser Arbeit als Standort 1, Standort 2, Standort 3 und Standort 4 bezeichnet:

- **Standort 1** (Rheinland-Pfalz),
- **Standort 2** (Baden-Württemberg),
- **Standort 3** (Rheinland-Pfalz),
- **Standort 4** (Rheinland-Pfalz).

Um dennoch eine geografische Einordnung zu ermöglichen, wird die ungefähre Lage der Standorte in der folgenden Karte (vgl. Abbildung 66) farblich dargestellt.

⁴⁷ 20.000 bis 100.00 Einwohner.



Abbildung 66: Ausschnitt der Karte von Deutschland – Markierung der ausgewählten Orte (Quelle: modifizierte Darstellung nach [154])

Für diese vier Standorte wurden die klimatischen Bedingungen (äußeren Umwelteinflüsse) erfasst, die sich auf die Entwicklung des Abnutzungsvorrats der dort befindlichen Gebäude auswirken. Bedingt dadurch, dass bei der Datenauswahl (vgl. Kapitel 8.2.3) ausschließlich Gebäude berücksichtigt werden, mit Baujahr ≥ 1973 , ist eine klimatische Betrachtung der Zeiträume vor 1973 nicht relevant.

In der Klimatologie ist es üblich, für die Erfassung des Klimas Mittelwerte über einen Zeitraum von 30 Jahren zu bilden, um die Auswirkungen der natürlichen Variabilität aus der statistischen Betrachtung zu minimieren. Mit diesen langjährigen Mittelwerten ist es möglich, den Klimazustand einzelner Regionen zu vergleichen [155].

Der Deutsche Wetterdienst bietet dazu u.a. Datensätze für die Betrachtungszeiträume 1961 – 1980, 1971 – 2000, 1981 – 2010 und 1991 – 2020 an. In der vorliegenden Arbeit wird der Betrachtungszeitraum von 1991 bis 2020 als am besten geeignet angesehen, da er die größte Schnittmenge mit den Lebensdauern der Gebäude des Datensatzes aufweist.

Neben den klimatischen Bedingungen werden auch weitere äußere Umwelteinflüsse wie der Wind oder Erdbeben (Erschütterung) berücksichtigt.

Im Folgenden werden die äußeren Umwelteinflüsse für die vier genannten Standorte erläutert.

7.2 Standort 1 in Rheinland-Pfalz

Nach dem Deutschen Wetterdienst [155] wurden am Standort 1 im vieljährigen Mittel zwischen 1991 und 2020 folgende Werte gemessen:

- Temperatur: 10,8 C° (Grad Celsius),
- Niederschlag: 585 mm (Millimeter),
- Frosttage: 51,8 (Anzahl),
- Sonnenscheindauer: 1675,5 h (Stunden).

Nach den Hagelzonen der Münchener Rück (vgl. Abbildung 58) wird Standort 1 der Hagelzone 10 zugeordnet. Standort 1 wird nach den erweiterten Schneelastzonen (vgl. Abbildung 61) der Schneelastzone 1 zugeordnet.

Auf Basis der DIN EN 1991-1-4/NA:2010-12 (vgl. Abbildung 64) wird der Standort der Windlastzone 1 zugeordnet.

Erschütterung: Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R} \leq 1,0 \text{ m/s}^2$ (vgl. Abbildung 56). Eine grafische Darstellung der spektralen Antwortbeschleunigung können Sie dem Plot in der Abbildung 66 entnehmen.




Abbildung 67: Plot Spektrale Antwortbeschleunigung für den Standort 1 (475a) (Quelle: [156])

7.3 Standort 2 in Baden-Württemberg

Nach dem Deutschen Wetterdienst [155] wurden am Standort 2 im vieljährigen Mittel zwischen 1991 und 2020 folgende Werte gemessen:

- Temperatur: 10,9 C° (Grad Celsius),
- Niederschlag: 711,9 mm (Millimeter),

- Frosttage: 62,6⁴⁸ (Anzahl),
- Sonnenscheindauer: 1734,2 h (Stunden).

Nach den Hagelzonen der Münchener Rück (vgl. Abbildung 58), wird der Standort der Hagelzone 15 zugeordnet. Der Standort 2 wird nach den erweiterten Schneelastzonen (vgl. Abbildung 61) der Schneelastzone 2 zugeordnet.

Auf Basis der DIN EN 1991-1-4/NA:2010-12 (vgl. Abbildung 64) wird der Standort 2 der Windlastzone 1 zugeordnet.

Erschütterung: Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R} \leq 0,5 \text{ m/s}^2$ (vgl. Abbildung 56). Eine grafische Darstellung der spektralen Antwortbeschleunigung können Sie dem Plot in der Abbildung 67 entnehmen.




Abbildung 68: Plot Spektrale Antwortbeschleunigung für den Standort 2 (475a) (Quelle: [156])

7.4 Standort 3 in Rheinland-Pfalz

Nach dem Deutschen Wetterdienst [155] wurden am Standort 3 im vieljährigen Mittel zwischen 1991 und 2020 folgende Werte gemessen:

- Temperatur: 10,5 C° (Grad Celsius),
- Niederschlag: 633,3 mm (Millimeter),
- Frosttage: 63,8 (Anzahl),
- Sonnenscheindauer: 1575 h (Stunden).

⁴⁸ Für die Anzahl der Frosttage liegen bei dem DWD für die Messtation 2095 keine konkreten Messdaten vor. Der vieljährige Mittelwert wurde daher dem Raster urn:x-wmo:md:de.dwd.cdc::GRD_DEU_P1Y_T2M-N_LT0 (Version 19.3) des Climate Data Center des DWD [157] entnommen.

Nach den Hagelzonen der Münchener Rück (vgl. Abbildung 58), wird der Standort 3 der Hagelzone 7.5 zugeordnet. Der Standort wird nach den erweiterten Schneelastzonen (vgl. Abbildung 61) der Schneelastzone 1 zugeordnet.

Auf Basis der DIN EN 1991-1-4/NA:2010-12 (vgl. Abbildung 64) wird der Standort 3 der Windlastzone 2 zugeordnet.

Erschütterung: Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R} \leq 1,6 \text{ m/s}^2$ (vgl. Abbildung 56). Eine grafische Darstellung der spektralen Antwortbeschleunigung können Sie dem Plot in der Abbildung 69 entnehmen.




Abbildung 69: Plot Spektrale Antwortbeschleunigung für den Standort 3 (475a) (Quelle: [156])

7.5 Standort 4 in Rheinland-Pfalz

Nach dem Deutschen Wetterdienst [155] wurden am Standort 4 im vieljährigen Mittel zwischen 1991 und 2020 folgende Werte gemessen:

- Temperatur: 10,9 C° (Grad Celsius),
- Niederschlag: 690 mm (Millimeter),
- Frosttage: 62,9 (Anzahl).
- Sonnenscheindauer: 1652,1 h (Stunden).

Nach den Hagelzonen der Münchener Rück (vgl. Abbildung 58), wird der Standort 4 der Hagelzone 7.5 zugeordnet. Der Standort wird nach den erweiterten Schneelastzonen (vgl. Abbildung 61) der Schneelastzone 2 zugeordnet.

Auf Basis der DIN EN 1991-1-4/NA:2010-12 (vgl. Abbildung 64) liegt dieser Standort exakt auf der Grenze zwischen der Windlastzone 1 und der Windlastzone 2, daher wird dem Standort 4 der Mittelwert 1,5 zugeteilt.

Erschütterung: Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R} \leq 0,3 \text{ m/s}^2$ (vgl. Abbildung 56). Eine grafische Darstellung der spektralen Antwortbeschleunigung können Sie dem Plot in der Abbildung 70 entnehmen.




Abbildung 70: Plot Spektrale Antwortbeschleunigung für den Standort 4 (475a) (Quelle: [156])

7.6 Zusammenfassung

Die Zusammenfassung der standortabhängigen vieljährigen Mittelwerte für die Temperatur, den Niederschlag und die Sonnenscheindauer können Sie der Tabelle 16 entnehmen.

Tabelle 16: Zusammenfassung Lufttemperatur, Niederschlag und Sonnenscheindauer (Quelle: eigene Darstellung)

| | Lufttemperatur ⁴⁹ | Niederschlag ⁵⁰ | Sonnenscheindauer ⁵¹ |
|-------------------|------------------------------|----------------------------|---------------------------------|
| Standort 1 | 10,8 C° | 585 mm | 1675,5 h |
| Standort 2 | 10,9 C° | 711,9 mm | 1734,2 h |
| Standort 3 | 10,5 C° | 633,3 mm | 1575 h |
| Standort 4 | 10,9 C° | 690 mm | 1652 h |

In der Tabelle 17 sind die Windlastzonen, Schneelastzonen sowie die Erschütterung am jeweiligen Standort dargestellt.

⁴⁹ Vieljährige Mittelwerte 1991 – 2020.

⁵⁰ Vieljährige Mittelwerte 1991 – 2020.

⁵¹ Vieljährige Mittelwerte 1991 – 2020.

Tabelle 17: Zusammenfassung Windlastzone, Schneelastzone und Erschütterung (Quelle: eigene Darstellung)

| | Windlastzone ⁵² | Schneelastzone ⁵³ | Erschütterung ⁵⁴ |
|-------------------|----------------------------|------------------------------|-----------------------------|
| Standort 1 | 1 | 1 | $\leq 1,0 \text{ m/s}^2$ |
| Standort 2 | 1 | 2 | $\leq 0,5 \text{ m/s}^2$ |
| Standort 3 | 2 | 1 | $\leq 1,6 \text{ m/s}^2$ |
| Standort 4 | 1.5 | 2 | $\leq 0,3 \text{ m/s}^2$ |

In der Tabelle 18 sind die Hagelzonen und Frosttage der Standorte gegenübergestellt. Als Frosttag werden Tage definiert, an denen die Temperatur unter 0 C° fällt.

Tabelle 18: Zusammenfassung Hagelzone und Frosttage (Quelle: eigene Darstellung)

| | Hagelzone ⁵⁵ | Frosttage ⁵⁶ |
|-------------------|-------------------------|-------------------------|
| Standort 1 | 10 | 51,8 |
| Standort 2 | 15 | 62,6 |
| Standort 3 | 7,5 | 63,8 |
| Standort 4 | 7,5 | 62,9 |

⁵² Nach der DIN EN 1991-1-4/NA:2010-12.

⁵³ Nach der DIN EN 1991-1-3/NA.

⁵⁴ Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R}$.

⁵⁵ Nach den Hagelzonen der Münchener Rück (vgl. Abbildung 58).

⁵⁶ Vieljährige Mittelwerte 1991 – 2020.

8 Datengrundlage

8.1 Dysisko-Datenbank

In der Datenbank der Software *dysisko*⁵⁷ (dynamische Instandsetzungskosten) des Unternehmens LifeCycle-Competence liegen die Informationen zu über 2000 Gebäuden verschiedener kommunaler Gebäudearten in Süd-West-Deutschland vor.

Diese Daten umfassen neben den allgemeinen Informationen wie beispielsweise Gebäudeart, Baujahr, Adresse, Bruttogrundfläche usw. unter anderem auch eine, bei der Ortsbegehung der Objekte angelegte Übersicht der identifizierten Bauelemente der jeweiligen Gebäude. Die Struktur der erfassten Bauelemente orientiert sich dabei an der Kostengruppenstruktur von DIN 276 „Kosten im Bauwesen - Ermittlung und Gliederung von Kosten im Bauwesen“, Stand 2018-12 (vgl. Abbildung 71).

300 Bauwerk – Baukonstruktionen

- 322 Flachgründungen
- 323 Tiefgründungen
- 324 Unterböden und Bodenplatten
- 325 Bodenbeläge
- 326 Bauwerksabdichtung
- 327 Dränagen
- 329 Gründung, sonstiges
- 331 Tragende Außenwände
- 332 Nichttragende Außenwände
- 333 Außenstützen
- 334 Außentüren und -fenster
 - 1 Außentüren
 - 2 Außenfenster
- 335 Außenwandbekleidungen, außen
 - 0 Durchschnitt
 - 1 Putz
 - 2 Mauerwerk
 - 3 Platten bzw. Stein
 - 4 Holz
 - 5 Metall
- 336 Außenwandbekleidungen, innen
- 337 Elementierte Außenwände
- 338 Sonnenschutz
- 339 Außenwände, sonstiges
- 341 Tragende Innenwände
- 342 Nichttragende Innenwände
- 343 Innenstützen
- 344 Innentüren und -fenster

400 Bauwerk – technische Anlagen

- 411 Abwasseranlagen
- 412 Wasseranlagen
- 413 Gasanlagen
- 419 Abwasser-, Wasser-, Gasanlagen, Sonstiges
- 421 Wärmeerzeugungsanlagen
 - 0 keine Angaben
 - 1 Öl
 - 2 Gas
 - 3 Pellets
 - 4 Wärmepumpe
 - 5 Kraft-Wärme-Kopplung
 - 6 Fernwärme
- 422 Wärmeverteilnetze
- 423 Raumheizflächen
- 429 Wärmeversorgungsanl., sonstiges
- 431 Lüftungsanlagen
 - 1 einfach
 - 2 hochwertig
- 432 Teilklimaanlagen
- 433 Klimaanlagen
- 434 Kälteanlagen
- 439 Lufttechnische Anlagen, sonstiges
- 441 Hoch- und Mittelspannungsanlagen
- 442 Eigenstromversorgungsanlagen
- 443 Niederspannungsschaltanlagen
- 444 Niederspannungsinstallationsanlagen
- 445 Beleuchtungsanlagen
- 446 Blitzschutz- und Erdungsanlagen

Abbildung 71: Ausschnitt der Struktur der Bauelemente der Gebäude in *dysisko* (Quelle: eigene Darstellung)

Die vorliegenden Datensätze stammen aus der operativen Tätigkeit der Firma LifeCycle-Competence, die im Auftrag kommunaler Einrichtungen eine umfassende Untersuchung von Bauwerken durchgeführt hat. Ziel dieses Prozesses war die vollständige Erfassung aller

⁵⁷ „*dysisko*“ ist das Produkt der Forschungsprojekte „Instandhaltungsmanagement für Immobilien als nachhaltiges Element des Facility Managements [FM^EM]“ [25] und „Instandhaltungsmanagement für Immobilien als nachhaltiges Element des Facility Managements [FM^EM 2] - Überführung der Methode > *dysisko* < in einer Softwareversion mit praxisbezogenem Anwendungstest“ [26] des Fachgebietes Baubetrieb & Bauwirtschaft der Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau. Das Kernforschungsteam gründet sich nach Forschungsprojekten mit dem Unternehmen LifeCycle-Competence aus und entwickelte aus den Prototypen ein marktreifes Produkt.

Bauteilzustände innerhalb dieser Bauwerke und die daraus resultierende Erstellung von Lebenszykluskostenprognosen.

Die im Untersuchungszeitraum 2019 bis 2021 im Rahmen der Inspektionstätigkeit erfassten Datensätze werden in einer relationalen Datenbank konsolidiert und verwaltet. Im Rahmen des Forschungsprojektes "Operationalisierung mittels künstlicher Intelligenz bei Gebäuden" (OPKI) [19] wurden diese Datensätze für wissenschaftliche Forschungszwecke exportiert.

Die Integration dieser Daten in den Anhang dieser wissenschaftlichen Arbeit wurde aus Gründen des Datenschutzes unterlassen.

Bei einer Begehung der Gebäude werden die Zustände eines jeden verbauten Bauelementes und identifizierte Instandsetzungsjahre von einem Experten erfasst und in die Datenbank eingetragen. Die Zuordnung des Zustandes der Bauelemente erfolgt in der Form von Klassifizierungen des Abnutzungsvorrates. Dabei stehen die Klassifizierungen „A: Sehr gut“, „B: Gut“, „C: Akzeptabel“, „D: Schlecht“ und „E: Ende der Lebensdauer“ zur Auswahl. Numerisch bedeutet das, dass Bauteile im Zustand „A“ mindestens noch 90 % ihres Abnutzungsvorrates besitzen, maximal aber 100 %. Im Mittel besitzt ein Bauteil der Klassifizierung „A“ 95 % seines Abnutzungsvorrates. Bei der Klassifizierung „B“ liegt die Spanne zwischen 65 % und 90 %, im Mittel 77.5 %. Liegt der Abnutzungsvorrat zwischen 25 % und 65 % wird das Bauelement mit „C“ klassifiziert, der Mittelwert beträgt 45 %. Zwischen 5 % und 25 % befindet sich die Klassifizierung D (Mittelwert 15 %) und bei einem Abnutzungsvorrat von kleiner gleich 5 % (Mittelwert 2,5 %) befindet man sich in der Schlussklassifizierung „E“ (vgl. Abbildung 72).



Abbildung 72: Ausschnitt der Darstellung der Bauteilzustände in Dysisko (nach OPKI) (Quelle: eigene Darstellung)

Diese Kategorisierung orientiert sich an der Einteilung nach Krug [54], jedoch erweitert sie diese Skala um den Zustand E und setzt neue Grenzen fest. Einen Vergleich der verwendeten Skala, mit der in der Literatur oft verwendeten Skala von Krug können der Tabelle 19 entnehmen. Diese für OPKI entwickelte Skala wurde in die Software Dysisko implementiert.

Tabelle 19: Vergleich der Klassifizierungen nach Krug und OPKI (Quelle: eigene Darstellung nach [19, 54])

| Klassifizierung nach Krug [54] | | Klassifizierung OPKI [19] | |
|--------------------------------|----------------|---------------------------|----------------|
| Zustandsvariable | Grenzen | Zustandsvariable | Grenzen |
| A | 85 % bis 100 % | A | 90 % bis 100 % |
| B | 60 % bis 85 % | B | 65 % bis 90 % |
| C | 20 % bis 60 % | C | 25 % bis 65 % |
| D | 0 % bis 20 % | D | 5 % bis 25 % |
| | | E | 0 % bis 5 % |

Der Vorteil der OPKI-Skala gegenüber der Krug-Skala besteht darin, dass sie die Möglichkeit bietet, z.B. eine beschädigte Außenwand zu kennzeichnen, die sich in einem schlechten Zustand befindet, aber noch über eine ausreichende Tragfähigkeit verfügt. Im Gegensatz dazu ist bei der Einteilung nach Krug nicht eindeutig erkennbar, ob der Zustand D die vollständige Zerstörung eines Bauteils bedeutet oder ob das Bauteil möglicherweise noch seine bestimmungsgemäße Funktion erfüllt.

Von jedem einzelnen Bauteil werden digitale Bilder angefertigt und auf dem Server in Verbindung mit dem Gebäude hinterlegt, um einen Zustand zu einem späteren Zeitpunkt nachvollziehen und verifizieren zu können.

Für eine möglichst realistische Abbildung des gesamten Zustandes des Gebäudes besteht auch die Möglichkeit, Bauelemente prozentual mit unterschiedlichen Klassifizierungen zu bewerten. Das ist beispielsweise der Fall, wenn bei der Bewertung der Außenfenster auffällt, dass die Fenster der Wetterseite einen wesentlich schlechteren Zustand haben als die anderen drei Seiten des Gebäudes.



Abbildung 73: Ausschnitt der Inspektionsdaten Dysisko (Quelle: eigene Darstellung)

8.2 Datenaufbereitung

Für die Datenaufbereitung wurden in einem ersten Schritt alle verfügbaren Daten aus der Datenbank der Software *dysisko* über die XLS-Schnittstelle der Software in ein Tabellenkalkulationsprogramm (EXCEL) exportiert. Dabei wurden alle Bauteile der Gebäudehülle der Bestandsgebäude, mit Ausnahme der Gebäudetypen „Garagen“ und „Lagergebäude“, extrahiert.

Die extrahierten Daten umfassen den Gebäudenamen, die Postleitzahl des Standorts, das Baujahr, den Zustand der einzelnen Bauteile und das Jahr der Inspektion.

Hinweis: Lagen für ein einzelnes Bauteil unterschiedliche Klassifizierungen vor, beispielsweise weil die Fenster der Wetterseite in einem schlechteren Zustand sind als die Fenster der anderen Gebäudeseiten, wurde nur der schlechteste Zustand (worst-case) exportiert. Dies wird damit begründet, dass zur Vermeidung von Folgekosten der zuerst auftretende Schaden relevant ist.

Diese Basisdaten lagen nach dem Export in der Struktur, wie in der Tabelle 20 dargestellt, vor.

Tabelle 20: Struktur der Basisdaten (exemplarische Darstellung) (Quelle: eigene Darstellung)

| Basisdaten | | | | | | |
|------------|------------------|---------|------------|------|-----|--------|
| PLZ | GebäudeName | Baujahr | Inspektion | 3310 | ... | 3640 |
| 53489 | Bürogebäude Anto | 1985 | 2021 | 25 % | ... | 77,5 % |
| ... | ... | ... | ... | ... | ... | ... |

Wie die Beispieldaten in der Struktur der Tabelle 20 veranschaulichen, sind die Inspektionsdaten als prozentualer Abnutzungsvorrat für jedes Bauelement hinterlegt.

Das Kapitel Datenaufbereitung ist im Folgenden analog zur Datenaufbereitung (englisch: Data preparation) nach der ISO/IEC 23053 [80] aufgebaut (vgl. Kapitel 2.3.3.3), dabei ist anzumerken, dass manche Phasen wiederholt und durchlaufen wurden.

So wurde beispielsweise die grafische Auswertung, welche in der Phase Exploring erläutert wird, nach allen inhaltlichen Änderungen der Daten erneut durchgeführt. Dieser iterative Prozess, bei dem bestimmte Stufen wiederholt durchlaufen werden, wird aufgrund eines negativen Einflusses auf die Struktur des Kapitels vereinfacht linear dargestellt.

Als Überschriften werden die englischen Begriffe aus der ISO/IEC 23053 [80] verwendet.

8.2.1 Exploring

In der Explorationsphase (dt.: Erkundungsphase) wurden die Rohdaten aus Excel mit dem Programm SPSS⁵⁸ statistisch ausgewertet und grafisch (Histogramme) analysiert. Dabei ging es in erster Linie um Häufigkeitsverteilungen, Mittelwerte und die Ermittlung von Ausreißern. Inhaltliche Anpassungen wie beispielsweise die Löschung von Ausreißern fand in dieser Phase nicht statt.

Gemäß ISO/IEC 23053 [59] besteht das Ziel der Explorationsphase darin, Erkenntnisse zu gewinnen, „die bei der Entscheidung helfen, welche Prozesse erforderlich sind, um die Daten für das Modelltraining vorzubereiten“ [80] (S. 27) (übersetzt aus der englischen Sprache).

Nach jeder Änderung des Datensatzes wurden die Daten erneut grafisch ausgewertet, um ein besseres Verständnis der Auswirkungen dieser Änderung auf den Datensatz zu erhalten.

Die grafische Auswertung des finalen Datensatz finden Sie im Kapitel 8.3.

⁵⁸ SPSS (Statistical Package for the Social Science) ist ein Softwarepaket von IBM für die statistische Analyse von Daten.

8.2.2 Data wrangling

Das Ziel der Phase der Datenbereinigung bzw. Datenaufbereitung (engl.: data wrangling) ist nach der ISO/IEC 23053 [80] ein gut strukturierter und geordneter Datensatz.

Zu diesem Zweck wurden die Basisdaten (Tabelle 21) nach Bauteilen gruppiert und für jede Kostengruppe in neue Tabellen (vgl. Tabelle 22) übertragen.

Tabelle 21: Basisdaten (exemplarische Darstellung) (Quelle: eigene Darstellung)

| Basisdaten | | | | | | |
|------------|--------------------|---------|------------|------|-----|--------|
| PLZ | Gebäude | Baujahr | Inspektion | 3310 | ... | 3640 |
| 53xxx | Bürogebäude Anton | 1985 | 2021 | 25 % | ... | 77,5 % |
| ... | ... | ... | ... | ... | ... | ... |
| 74xxx | Bürogebäude Dexter | ... | ... | 33 % | ... | 41 % |

Tabelle 22: Basisdaten gruppiert nach Bauelementen (exemplarische Darstellung) (Quelle: eigene Darstellung)

| 3310 | | | | | ... | 3640 | | | | |
|-------|--------------------|---------|------------|------------------|-----|-------|-----|-----|-----|------------------|
| PLZ | Gebäude | Baujahr | Inspektion | Abnutzungsvorrat | ... | PLZ | ... | ... | ... | Abnutzungsvorrat |
| 53xxx | Bürogebäude Anton | 1985 | 2021 | 25 % | ... | 53xxx | ... | ... | ... | 77,5 % |
| ... | ... | ... | ... | | ... | ... | ... | ... | ... | |
| 74xxx | Bürogebäude Dexter | | | 33 % | ... | 74xxx | | | | 41 % |

Innerhalb dieser Tabellen erfolgte eine weitere Stufe der Gruppierung nach der Postleitzahl, um die Datensätze im späteren Verlauf mit den spezifischen äußeren Umwelteinflüssen verknüpfen zu können (vgl. Kapitel 8.2.6.2). Diese Unterteilung ist grafisch in der Tabelle 23 dargestellt. Bei Städten mit mehreren Stadtteilen, bei denen Daten zu mehreren Stadtteilen vorlagen, wurden die Daten unter der Postleitzahl zusammengefasst, zu der die meisten Daten vorlagen.

Für Standort 4 wurden die Postleitzahlen 54xxx, 54xxx, 54xxx, 54xxx, 54xxx, 54xxx und 54xxx unter der Postleitzahl 54xxx gruppiert. Am Standort 1 wurden die Postleitzahlen 55xxx, 55xxx, 55xxx, 55xxx, 55xxx, 55xxx, 55xxx und 55xxx unter der Postleitzahl 55xxx gruppiert.⁵⁹

Der Standort 2 sowie Standort 3 werden nicht in weitere Stadtteile unterteilt und besitzen damit nur eine Postleitzahl.

Eine exemplarische Darstellung der Datenstruktur kann der Tabelle 23 entnommen werden.

⁵⁹ Die Postleitzahlen wurden aus Datenschutzgründen unkenntlich gemacht.

Tabelle 23: Gruppierte Bauelemente, unterteilt nach Postleitzahlen (exemplarische Darstellung)
(Quelle: eigene Darstellung)

| 3310 | | | | | ... | 3640 | | | | |
|-------|--------------------|---------|------------|------------------|-----|-------|-----|-----|-----|------------------|
| PLZ | GebäudeName | Baujahr | Inspektion | Abnutzungsvorrat | ... | PLZ | ... | ... | ... | Abnutzungsvorrat |
| 53xxx | Bürogebäude Anton | 1985 | 2021 | 25 % | ... | 53xxx | ... | ... | ... | 77,5 % |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 53xxx | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 74xxx | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 74xxx | Bürogebäude Dexter | ... | ... | 33 % | ... | 74xxx | ... | ... | ... | 41 % |

Im nächsten Schritt wurde die Spalte „Inspektion“ durch die Spalte „Bauteilalter“ ersetzt. Das Bauteilalter ergibt sich aus der Subtraktion von Baujahr und Inspektionsjahr, dadurch können Abnutzungsvorräte aus verschiedenen Inspektionsjahren anhand des Bauteilalters verglichen werden.

Außerdem wurde die Spalte „Abnutzungsvorrat“ durch die Spalte „Zerfallsrate“ (vgl. Kapitel 9.2.5) ersetzt. Die Zerfallsrate beschreibt den prozentualen durchschnittlichen Verlust des Abnutzungsvorrates pro Jahr bis zum aktuellen Zeitpunkt. Eine Zerfallsrate von beispielsweise 1,5 bedeutet somit, dass das Bauteil bis zu einem spezifischen Zeitpunkt (Referenzjahr t)⁶⁰ durchschnittlich 1,5 % des Abnutzungsvorrates pro Jahr verloren hat. Aufgrund der nicht linearen Kurve des Abnutzungsvorrates verändert sich die Zerfallsrate in Abhängigkeit zum Bauteilalter (nicht linear).

Für die korrekte Berechnung der Zerfallsrate werden das Jahr des Einbaus sowie das Jahr der Inspektion zu Grunde gelegt. Aufgrund der hohen Relevanz der Zerfallsrate für die vorliegende Arbeit wird diese Thematik gesondert in Kapitel 9.2.5 ausführlich behandelt und erläutert.

⁶⁰ Der Zeitpunkt der Inspektion des Bauteiles (Ortsbegehung des Gebäudes) wird als Referenzjahr t definiert. Im Prototyp ist dabei möglich mit dem Referenzjahr die Zerfallsrate zu einem bestimmten Zeitpunkt zu prognostizieren.

Tabelle 24: Gruppierte Bauelemente, unterteilt nach Postleitzahlen (exemplarische Darstellung)
(Quelle: eigene Darstellung)

| 3310 | | | | | ... |
|-------|-----------------------|---------|-------------------|-------------------|-----|
| PLZ | Gebäude- name | Baujahr | Bauteil- alter | Zerfalls- rate | ... |
| 53xxx | Bürogebäude Anton | 1985 | 35 | 2,08 | ... |
| ... | ... | ... | ... | ... | ... |
| 53xxx | ... | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... | ... |
| 74xxx | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| 74xxx | Bürogebäude Dexter | ... | ... | ... | ... |

An dieser in der Tabelle 24 dargestellten Struktur wurde bis zur Phase der „Dataset composition“ (vgl. Kapitel 8.2.6) festgehalten.

Für jedes einzelne Bauteil wurde eine Tabelle mit dieser Struktur erstellt, in der die entsprechenden Daten für das jeweilige Bauteil zu finden sind. Der (gesamte) Datensatz besteht somit aus einer Sammlung von Tabellen mit Daten zu den Bauelementen bzw. Kostengruppen: 3310, 3341, 3342, 3351, 3370, 3620, 3631, 3632, 3633 und 3634.

Dieser Datensatz ist exemplarisch in der Abbildung 74 illustriert.

| PLZ | Gebäudename | Baujahr | Bauteilalter | Zerfallsrate |
|-------|-----------------------|---------|--------------|--------------|
| 53xxx | Bürogebäude Anto | 1985 | 35 | 2,08 |
| ... | ... | ... | ... | ... |
| 53xxx | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... |
| ... | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... |
| ... | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... |
| 74xxx | ... | ... | ... | ... |
| ... | ... | ... | ... | ... |
| 74xxx | Bürogebäude Dexter | ... | ... | ... |

Abbildung 74: Gesamtmenge der gruppierten Bauelemente, unterteilt nach Postleitzahlen (exemplarische Darstellung) (Quelle: eigene Darstellung)

8.2.3 Cleaning

Die ISO/IEC 23053 [80] beschreibt die Cleaning-Phase (dt.: Bereinigen) als vergleichbar mit der Data Wrangling-Phase, jedoch auf einer detaillierteren Ebene. Dabei werden die Datensätze auf fehlerhafte Daten überprüft und diese aus dem Datensatz entfernt oder durch Interpolation korrigiert.

Zu diesem Zweck wurden die Daten jedes einzelnen Gebäudes mit den zugehörigen Bildern nochmals überprüft, wobei insbesondere das Hauptaugenmerk auf Bauteilen lag, deren Zerfallsrate als Ausreißer definiert wurde.

In dieser Arbeit wird eine Zerfallsrate als Ausreißer definiert, wenn der Z-Wert $\geq |3|$ ist. Der Z-Wert berechnet sich nach Formel 8.1.

$$Z = \frac{X - \mu}{\sigma} \quad 8.1$$

(Quelle: nach [158])

- X ist ein einzelner Rohdatenwert,
- μ ist der Mittelwert des Datensatzes,
- σ ist die Standardabweichung des Datensatzes.

Der Datensatz entspricht dabei der Menge von Daten eines spezifischen Postleitzahlbereiches innerhalb eines Bauelementes. Die Standardabweichung und der Mittelwert bezieht sich damit nicht auf den vollständigen Datensatz. Für jedes Bauelement eines jeden Postleitzahlbereiches wurden spezifische Mittelwerte und Standardabweichungen berechnet.

Alle Ausreißer (Z-Wert $\geq |3|$)⁶¹ wurden aus den Datensätzen entfernt.

Neben der Löschung von Datensätzen, bei denen die Zerfallsrate stark von der Norm abweicht (Z-Wert), wurden auch alle Datensätze von Bauteilen gelöscht, bei denen erkennbar war oder der Verdacht bestand, dass eine Instandsetzung des Bauteils durchgeführt wurde.

Solch ein Verdacht ergibt sich beispielsweise, wenn ein Bauteil im Verhältnis zu dem gleichen Bauteil in anderen Gebäuden, einen sehr überdurchschnittlich guten Zustand besitzt.

Um sicherzustellen, dass instandgesetzte Bauteile älterer Gebäude nicht in die Trainingsdaten einfließen und damit die Auswertung verfälschen, wurden alle Gebäude mit einem Baujahr vor 1973 entfernt. Bei einer Inspektion im Jahr 2021 ist somit kein Bauteil älter als 48 Jahre, eine Instandsetzung wäre somit in den meisten Fällen an einer sehr niedrigen Zerfallsrate einfach zu identifizieren.

Darüber hinaus wurden alle Datensätze entfernt, die als nicht vergleichbar eingestuft wurden. Die hierfür definierten Einschränkungen (nicht vergleichbar) können der Tabelle 15 aus dem Kapitel 6 entnommen werden.

In der Summe ergaben sich nach der Datenbereinigung 1.652 verwertbare Datensätze für das Training des neuronalen Netzes, gruppiert nach den Kostengruppen (vgl. Anhang A 13).

Aufgrund der Tatsache, dass für einige Bauteile nach der Bereinigung weniger Daten vorlagen als für andere Bauteile (vgl. KG 3370 mit KG 3341 in Anhang A 13), wurde entschieden, die Daten mit synthetisch generierten Werten bis zu einem Gleichgewicht von 320 Datensätzen pro Bauteil aufzufüllen.

Dies wurde damit begründet, dass die Daten der einzelnen Bauteile im späteren Datensatz gleichmäßig verteilt sein sollten, um eine Verzerrung der Ergebnisse durch eine schiefe Datenbasis auszuschließen.

Die Zahl 320, 80 Datensätze pro Standort innerhalb einer Kostengruppe, ist das Ergebnis eines iterativen Prozesses, in dem getestet wurde, bei welcher Größe des Datensatzes das neuronale Modell eine optimale Qualität der Ergebnisse liefert, ohne durch eine zu hohe Anzahl synthetischer Daten von der tatsächlichen Datenbasis abzuweichen. Dazu wurde der Datensatz immer weiter mit synthetischen Daten aufgefüllt und beobachtet, wie sich die Genauigkeit (vgl. Kapitel 9.3.4) des neuronalen Modelles verändert.

Bei den Bauelementen 3631 und 3370 lagen zu wenig auswertbare Daten für die Umgebung des Standortes 3 (53xxx) vor, deswegen wurden Datensätze, die dem Standort 3 zugeordnet wurden, vollständig entfernt. Diese Bauelemente wurden bis zu einer Anzahl von 240⁶² Datensätzen synthetisch aufgefüllt.

Das in der Abbildung 75 dargestellte Verhältnis im endgültigen Datensatz zeigt ein Verhältnis von 46 % synthetischen Daten (1388 Einheiten) zu 54 % natürlichen Daten (1652 Einheiten).

⁶¹ Ein Z-Score mit einem Schwellenwert von 3 wird in der Statistik häufig als Hinweis auf einen möglichen Ausreißer betrachtet [159].

⁶² 80 Datensätze pro Standort innerhalb der Kostengruppe, d.h. $80 \times 3 (= 240)$.




Abbildung 75: Verhältnis im finalen Daten zwischen natürlichen und synthetischen Daten (Quelle: eigene Darstellung)

In Kapitel 8.3 wird gesondert auf die Methodik zur Erstellung dieser synthetischen Daten eingegangen.

8.2.4 Imputation

Im Entwurf der DIN EN ISO/IEC 23053 der Version April 2023 wird die Imputation folgendermaßen beschrieben: „Die Datenimputation bezieht sich auf einen Bereinigungsprozess, bei dem fehlende Daten durch substituierte Werte ersetzt werden.“ [160] (S. 35).

Während der Phase der Bereinigung der Daten wurde auf das Ersetzen von fehlerhaften Werten verzichtet, stattdessen wurden diese Datensätze vollständig gelöscht.

Für die Bereitstellung einer symmetrischen Datengrundlage wurden generell Datensätze synthetisch erzeugt. Methodisch wird dieses Vorgehen in Kapitel 8.3 näher erläutert.

8.2.5 Normalisation and scaling

Normalisierung beschreibt die Methode, alle Werte auf eine einheitliche Skala zu bringen. Diese einheitliche Skala reicht in der Regel von 0 bis 1, kann aber auch andere Werte annehmen. Einige ML-Algorithmen setzen eine Normalverteilung der Daten voraus, weichen die verwendeten Datensätze stark von einer Normalverteilung (Gauß-Verteilung) ab, können diese Daten durch eine Normalisierung in die Form einer Normalverteilung transformiert werden.

Bei der **Skalierung** werden die Daten so transformiert, dass sie in eine neue spezifische Skala passen, z. B. 0 - 1 oder 0 - 100, aber die Form der Daten wird nicht verändert (im Gegensatz zur Normalisierung). Bei der Skalierung wird ausschließlich der Bereich der Daten verändert, während bei der Normalisierung auch die Form der Verteilung der Daten verändert wird. Die Skalierung von Daten ermöglicht es, dass Daten mit unterschiedlichen Skalen vergleichbar werden. Eine Normalisierung wird hingegen angewendet, wenn der ML-Algorithmus Daten in einer Normalverteilung erwartet.

In der Literatur werden die Begriffe Normalisierung und Skalierung oft fälschlicherweise als Synonyme verwendet.

In der DIN EN ISO/IEC 23053 (Entwurf) [160] heißt es dazu: „Die Daten können skaliert oder normalisiert werden, um sicherzustellen, dass die Ergebnisse des Modells angemessen sind.“ [160] (S. 35).

Ein weiterer Begriff, der in diesem Zusammenhang oft genannt wird, ist die Standardisierung, daher wird auch diese hier kurz erläutert.

Bei der **Standardisierung** erhält man ein ähnliches Ergebnis wie bei der Normalisierung, das Ziel bei der Standardisierung ist aber, die Werte so zu verteilen, dass diese einen Mittelwert von 0 haben und die Standardabweichung bei 1 liegt.

Der primäre Unterschied zwischen der Standardisierung und der Normalisierung besteht darin, dass die Standardisierung nicht empfindlich auf Ausreißer reagiert, während die Normalisierung sehr empfindlich auf Ausreißer reagiert und von diesen stark beeinflusst wird.

Die Daten wurden während der Datenaufbereitung weder normalisiert noch standardisiert. Die Normalisierung, Standardisierung oder Skalierung erfolgte nachträglich in Python durch das Zurückgreifen auf bereits implementierte Normalisierungs-, Standardisierungs- und Skalierungsfunktionen.

In diesem Fall wurde die Funktion „StandardScaler()“ aus der Python-Bibliothek scikit-learn verwendet.

Weitere Erläuterungen diesbezüglich finden Sie in Kapitel 9.1.

Generell empfiehlt die ISO/IEC 23053:2022 [80] für die Normalisierung drei Techniken:

- Min-Max-Normalisierung,
- Z-Score Normalisierung,
- Dezimalskalierung.

8.2.6 Dataset composition

8.2.6.1 Allgemeines

Die Zusammenstellung (engl.: composition) der Datensätze ist bei der Aufbereitung von Daten für Regressionsmodelle für gewöhnlich der letzte Schritt. Dieses Zusammenstellen der Daten zu einem einzigen Datensatz „erfolgt in der Regel unter Berücksichtigung der zu trainierende Merkmale und einer ausreichenden Verteilung und Darstellung der Objekte für das Training der beabsichtigten Merkmale.“ [160] (S. 35).

Das Kapitel der Zusammenstellung der Datensätze lässt sich in die folgenden drei Unterkapitel untergliedern:

- Verknüpfung der Bauelemente mit den Umweltbedingungen,
- Zusammenführung der Bauelemente,
- One-Hot Kodierung.

8.2.6.2 Verknüpfung der Bauelemente mit den äußeren Umweltbedingungen

In einem ersten Schritt wurden die Daten der einzelnen Bauteile über die Postleitzahl mit den Umweltbedingungen auf der Grundlage der Tabelle 16, Tabelle 17 und Tabelle 18 aus dem Kapitel 7.6 ergänzt.

Aus der Verknüpfung der Umweltbedingungen, wie in der Tabelle 25 dargestellt, und den Daten der Bauelemente (vgl. Tabelle 26) resultierte eine neue Tabellenstruktur, dargestellt in der Tabelle 27.

Tabelle 25: Standortabhängige Umweltbedingungen (Quelle: eigene Darstellung)

| Standortabhängigen Umweltbedingen | | | | |
|-----------------------------------|----------------|--------------|-----|-----|
| Ort/PLZ | Lufttemperatur | Niederschlag | ... | ... |
| Standort 3/53xxx | 10,5 C° | 633,3 mm | ... | ... |
| Standort 4/54xxx | ... | ... | ... | ... |
| Standort 1/55xxx | ... | ... | ... | ... |
| Standort 2/74xxx | ... | ... | ... | ... |

Tabelle 26: Gruppierte Bauelemente, unterteilt nach Postleitzahlen - ohne Umweltbedingungen (exemplarische Darstellung) (Quelle: eigene Darstellung)

| 3310 (ohne Umweltbedingungen) | | | | |
|-------------------------------|-------------|--------------|---------|--------------|
| PLZ | Gebäudename | Bauteilalter | Baujahr | Zerfallsrate |
| 53xxx | ... | ... | ... | 2,08 |
| ... | ... | ... | ... | ... |
| 53xxx | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... |
| ... | ... | ... | ... | ... |
| 54xxx | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... |
| ... | ... | ... | ... | ... |
| 55xxx | ... | ... | ... | ... |
| 74172 | ... | ... | ... | ... |
| ... | ... | ... | ... | ... |
| 74172 | ... | ... | ... | ... |

Tabelle 27: Gruppierte Bauelemente, unterteilt nach Postleitzahlen - mit Umweltbedingungen (exemplarische Darstellung) (Quelle: eigene Darstellung)

| 3310 (mit Umweltbedingungen) | | | | | |
|------------------------------|--------------|-----|--------------|---------|--------------|
| Lufttemperatur | Niederschlag | ... | Bauteilalter | Baujahr | Zerfallsrate |
| 10,5 C° | 633,3 mm | ... | ... | ... | 2,08 |
| ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| 10,9 C° | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |

Die neue Datenstruktur (vgl.

Tabelle 27) enthält keine Postleitzahlen oder Gebäudenamen mehr, da diese für das weitere Vorgehen nicht mehr relevant sind.

8.2.6.3 Zusammenführung der Bauelemente

Im zweiten Schritt werden alle Bauteiltabellen in einer einzigen Tabelle zusammengefasst. Die daraus resultierende Struktur enthält die neue Spalte „KG“ (Kostengruppe), mit der die Datensätze einem Bauelement zugeordnet werden können. Dargestellt ist diese neue Struktur in der Tabelle 28.

Tabelle 28: Datensatz - Zusammenführung aller Bauelemente (exemplarische Darstellung) (Quelle: eigene Darstellung)

| Datensatz | | | | | | |
|----------------|--------------|-----|------|--------------|---------|--------------|
| Lufttemperatur | Niederschlag | ... | KG | Bauteilalter | Baujahr | Zerfallsrate |
| 10,5 C° | 633,3 mm | ... | 3310 | ... | ... | 2,08 |
| | ... | ... | 3341 | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... |
| 10,9 C° | ... | ... | 3310 | ... | ... | ... |
| ... | ... | ... | 3341 | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... |

Für die Verwendung als Datensatz im neuronalen Modell wurden die Daten der Tabelle 28 als CSV-Liste⁶³ exportiert.

8.2.6.4 One-Hot Kodierung

Bei Verwendung der Datenstruktur aus der Tabelle 28 ergab sich beim Training des neuronalen Modells das Problem, dass die numerischen Werte (Kostengruppen) der Bauteile kategorial nicht korrekt interpretiert wurden. Um auszuschließen, dass das Modell in die numerischen Werte eine numerische Bedeutung oder eine ordinale Reihenfolge interpretiert, obwohl es sich bei den Bauelementen um Kategorien handelt, wurden die numerischen Werte der Bauteile „one-hot“ codiert.

Die One-Hot-Kodierung ist eine häufig verwendete Methode beim maschinellen Lernen für den Umgang mit kategorialen Daten. Die kategorialen Daten können dabei entweder nominal oder ordinal sein [161].

⁶³ CSV (Comma separated values) ist ein vereinfachtes Datenformat für den Datenaustausch von einfach strukturierten Tabellenlisten. Für die Trennung der Daten wird ein Komma benutzt.

Ordinale Daten weisen eine Rangfolge ihrer Werte auf, wie beispielweise Schulnoten mit den Noten 1 bis 6. Nominaldaten weisen keine Rangordnung untereinander auf, wie beispielsweise die Geschlechter: männlich oder weiblich [162].

Für jeden eindeutigen Wert in der ursprünglichen kategorialen Spalte wird bei der One-Hot-Codierung eine neue Spalte erstellt. Diese Dummy-Variablen werden dann mit Nullen und Einsen aufgefüllt (1 bedeutet WAHR, 0 bedeutet FALSCH) [163].

Die fertige Kodierung ist in der Abbildung 76 an einem Ausschnitt illustriert.

| 3310 | 3341 | 3342 | 3351 | 3370 | 3620 | 3631 | 3632 | 3633 | 3634 |
|------|------|------|------|------|------|------|------|------|------|
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 |
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 |
| 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |
| 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 |
| 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Abbildung 76: Ausschnitt der One-Hot kodierten Kostengruppen (Quelle: eigene Darstellung)

Für die Datenstruktur bedeutet diese Kodierung, dass die allgemeine Spalte „KG“ entfällt und dafür 10 weitere Spalten, eine für jede Kostengruppe, hinzugefügt werden, wie exemplarisch in der Tabelle 29 dargestellt ist.

Tabelle 29: Datensatz – One-Hot kodiert (exemplarische Darstellung) (Quelle: eigene Darstellung)

| Datensatz | | | | | | | | |
|----------------|--------------|-----|------|------|-----|--------------|---------|--------------|
| Lufttemperatur | Niederschlag | ... | 3310 | 3341 | ... | Bauteilalter | Baujahr | Zerfallsrate |
| 10,5 C° | 633,3 mm | ... | 1 | 0 | ... | ... | ... | 2,08 |
| ... | ... | ... | 0 | 1 | ... | ... | ... | ... |
| ... | ... | ... | ... | 0 | ... | ... | ... | ... |
| 10,9 C° | ... | ... | 1 | 0 | ... | ... | ... | ... |
| ... | ... | ... | 0 | 1 | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... | ... |

Für die Verwendung als Datensatz im neuronalen Modell wurden die Daten der Tabelle 29 als CSV-Liste exportiert.

8.2.7 Dataset splitting

Die Aufteilung (engl.: *splitting*) der Daten in Trainings-, Validierungs- und Testdaten erfolgte während des Trainings des neuronalen Modelles und nicht vorab bei der Datenaufbereitung. Verwendet wir dort die Funktion „*train_test_split*“ aus der Python-Bibliothek *scikit-learn*. Weitere Erläuterungen diesbezüglich finden Sie in Kapitel 9.1.

8.2.8 Labeling

Die Daten waren von Anfang an schon beschriftet (engl.: *Label*) und mussten daher nicht nachträglich gelabelt bzw. beschriftet werden. Das Label bzw. die Beschriftung ist die Zerfallsrate $Zr(t)$.

8.3 Erzeugung synthetischer Daten

Wie bereits in den vorangegangenen Kapiteln zur Datenaufbereitung beschrieben, wurde der Originaldatensatz mit Hilfe synthetischer Daten ergänzt, um eine Ausgewogenheit zwischen den Kostengruppen und auch den Einflussfaktoren zu erreichen. Ausgewogenheit bezieht sich diesbezüglich auf Form der Verteilung der vorliegenden Daten.

Die Entscheidung, synthetische Daten in die Trainingsläufe des neuronalen Modells zu integrieren, wurde getroffen, da das Modell während der anfänglichen Trainingsdurchläufe unter ausschließlicher Verwendung der natürlichen Daten keine zufriedenstellende Genauigkeit (vgl. Kapitel 9.3.4) erzielte. In dieser Phase konnte nie eine Genauigkeit erreicht werden, die über 80 % lag.

Die These, welche sich später bestätigen sollte, war, dass die Gesamtmenge der Daten zu asymmetrisch verteilt war. Es lagen zu großen Diskrepanzen in der gleichmäßigen Verteilung der Daten vor.

Deshalb lag der Schwerpunkt bei der Generierung der synthetischen Daten darauf, die Schiefe der Daten bestmöglich zu korrigieren, um eine Beeinträchtigung des Trainings zu vermeiden und eine höhere Genauigkeit zu erzielen. Schiefe Datenverteilungen können beim Training eines neuronalen Modells dazu führen, dass bestimmte Werte ungleichmäßig gut prognostiziert werden können, was sich negativ auf die allgemeine Genauigkeit des Modells auswirkt.

Die sogenannten Schiefe gibt dabei an, ob die Daten symmetrisch verteilt sind oder nicht, die Daten können dabei eine rechtsschiefe (engl.: *positiv skew*) und linksschiefe (engl.: *negative skew*) haben. Befinden sich die Daten in einer perfekten Normalverteilung, beträgt die Schiefe Null, die Daten gelten als vollkommen symmetrisch verteilt. Zur Bestimmung einer Normalverteilung wird in der Statistik neben der Schiefe auch die sogenannte Kurtosis⁶⁴ (= Wölbung)

⁶⁴ Die Kurtosis, Maßzahl für die Steilheit einer statistischen Dichtefunktion, Häufigkeitsverteilung oder einer Wahrscheinlichkeitsfunktion, die auf den englischen Mathematiker und Biostatistiker Karl Pearson (1857 bis 1936 [164]) zurückgeht, wird in der englischsprachigen Literatur häufig auch als „*Pearson's kurtosis*“ bezeichnet.

berechnet. Während die Schiefe eine statistische Kennzahl für die Symmetrie der Verteilung ist, gibt die Kurtosis an, wie spitz oder flach eine Verteilung ist.

Neben der Eigenschaft neuronaler Modelle, teilweise bei symmetrischen und/oder normalverteilten Daten eine *bessere Leistung*⁶⁵ zu erzielen, existieren in der Korrelationsanalyse auch Korrelationskoeffizienten, die die Annahme einer Normalverteilung voraussetzen.

Auf die konkrete Berechnung von der Schiefe und der Kurtosis wird in dieser Arbeit nicht näher eingegangen, Erläuterungen zu den Berechnungen finden sich u.a. in „Parametrische Statistik“ von Dormann [165].

In modernen Statistikprogrammen, wie z. B. SPSS, ist es möglich, die Schiefe und die Kurtosis von Verteilungen automatisch zu berechnen.

Als Richtwerte für die Schiefe und die „excess Kurtosis“⁶⁶ wird in der Literatur oft auf die Aussage von Hair [166] verwiesen:

„A general guideline for skewness is that if the number is greater than +1 or lower than -1, this is an indication of a skewed distribution. For kurtosis, the general guideline is that if the number is greater than +1, the distribution is too peaked. Likewise, a kurtosis of less than -1 indicates a distribution that is too flat. Distributions exhibiting skewness and/or kurtosis that exceed these guidelines are considered nonnormal.“

(Quelle: [166] S. 54)

Nach Bulmer [167] liegt bei einer Schiefe von $> |1|$ eine starke Schiefe, ab $> |0,5|$ eine mäßige Schiefe und bei Werten darunter eine annähernde Symmetrie vor.

George und Mallery [168] definieren die Schranken für eine Normalverteilung nicht so streng und bezeichnen Verteilungen mit einer Kurtosis bis $|2|$ als normal.

Als Beispiele für eine (mäßige) linksschiefe Verteilung dient Abbildung 77 bzw. für eine (mäßige) rechtsschiefe Verteilung die Abbildung 78.

⁶⁵ eine bessere Leistung wird hier mit einer höheren Prognosegenauigkeit gleichgesetzt (vgl. Kapitel 9.3.4).

⁶⁶ in der Literatur und in Statistikprogrammen wird häufig die excess Kurtosis verwendet; nach Pearson liegt eine Normalverteilung vor, wenn die Kurtosis = 3 ist. Die Exzess-Kurtosis ist definiert als Pearson-Kurtosis minus 3. Das heißt, dass eine optimal Normalverteilung vorliegt, wenn die excess Kurtosis bei 0 liegt.




Abbildung 77: Beispiel für eine (mäßige) links-schiefe Datenverteilung (Quelle: eigene Darstellung)

Schiefe (SPSS): -0,972

Excess Kurtosis (SPSS): -0,821




Abbildung 78: Beispiel für eine (mäßige) rechtsschiefe Datenverteilung (Quelle: eigene Darstellung)

Schiefe (SPSS): 0,796

Excess Kurtosis (SPSS): -1,039

Die Methodik zur Generierung der synthetischen Daten beruhte auf der Implementierung kleiner KI-Module, die explizit für die jeweiligen Elemente der spezifischen Kostengruppe erstellt wurden. Der Aufbau dieser Module leitete sich aus dem primären neuronalen Modell ab, welches für den zusammengesetzten Datensatz entwickelt wurde (vgl. Kapitel 9.3), aus diesem Grund wird an dieser Stelle nicht näher auf den konkreten Aufbau des neuronalen Modelles eingegangen.

Im Gegensatz zu dem primären neuronalen Modell, welches zu *diesem Zeitpunkt*⁶⁷ eine Genauigkeit von lediglich 80 % bei seinen Vorhersagen erzielte, lieferten die Modelle, welche nur mit den Daten für eine spezielle Kostengruppe trainiert wurden, erheblich höhere Genauigkeiten (> 90 %) bei den Vorhersagen.

Unter Verwendung dieser KI-Module wurden für jedes Bauelement in jeder Kostengruppe synthetische Daten generiert. Die Generierung erfolgte methodisch durch ein Python-Skript, welches Zufallsdaten innerhalb der Grenzen der bereits vorhandenen Daten erzeugte. Anschließend wurde über das Python KI-Modul die entsprechende Zerfallsrate prognostiziert.

Dieses Vorgehen wurde für jede Kostengruppe wiederholt, um eine Menge von 240 bzw. 320 Datensätzen pro Kostengruppe zu erstellen, die für das Training des neuronalen Netzwerkes verwendet wurden.

Insgesamt ergab sich ein Datensatz von 2.560 Datensätzen, wie in der Tabelle 30 dargestellt. Anschließend wurde der vorliegende Datensatz in Excel randomisiert. Dieser Schritt wurde durchgeführt, um sicherzustellen, dass die Ergebnisse des neuronalen Modells nicht durch mögliche Muster oder Cluster in den Daten beeinflusst oder verzerrt werden.

⁶⁷ Damit ist der Zeitpunkt gemeint, als noch keine synthetischen Daten für das Training verwendet wurden.

Tabelle 30: Aufbau des Datensatzes nach Ergänzung durch synthetische Daten (Quelle: eigene Darstellung)

| Bauelement | Anzahl an Datensätzen (ohne synthetische Daten) | Anzahl an Datensätzen (mit synthetischen Daten) |
|-------------------|--|--|
| KG 3310 | 153 | 320 |
| KG 3341 | 262 | 320 |
| KG 3342 | 230 | 320 |
| KG 3351 | 113 | 320 |
| KG 3370 | 91 | 240* |
| KG 3620 | 130 | 320 |
| KG 3631 | 129 | 240* |
| KG 3632 | 136 | 320 |
| KG 3633 | 165 | 320 |
| KG 3634 | 243 | 320 |
| Summe | 1652 | 2560 |

(*) Bei den Bauelementen 3631 und 3370 lagen zu wenig auswertbare Daten für die Umgebung des Standorts 3 (53xxx) vor, deswegen wurden Datensätze, die dem Standort 3 zugeordnet wurden, vollständig entfernt. Diese Bauelemente wurden bis zu einer Anzahl von 240 Datensätzen synthetisch aufgefüllt.

Aufgrund der synthetischen Daten konnte eine symmetrische Verteilung innerhalb der Bauelemente (Kostengruppen) und einiger Einflussfaktoren hergestellt oder zumindest verbessert werden.

Die Schiefe der Verteilungen der Parameter im zusammengesetzten Datensatz kann der Tabelle 31 entnommen werden. Nach Bulmer [167] liegen die Frosttage leicht über der Grenze zu einer starken Schiefe, alle anderen Parameter sind im Bereich einer annähernden Symmetrie oder einer mäßigen Schiefe verteilt.

Tabelle 31: Schiefe der Parameter im zusammengesetzten Datensatz (SPSS) (Quelle: eigene Darstellung)

| Parameter | Schiefe nach SPSS | Bewertung nach Bulmer [167] | Bewertung nach Hair [166] |
|-------------------|-------------------|-----------------------------|---------------------------|
| Alter | -0,567 | mäßige Schiefe | - |
| Baujahr | 0,567 | mäßige Schiefe | - |
| Erschütterung | 0,438 | annähernde Symmetrie | - |
| Frosttage | -1,130 | starke Schiefe | schiefe Verteilung |
| Hagelzone | 0,796 | mäßige Schiefe | - |
| Niederschlag | -0,271 | annähernde Symmetrie | - |
| Schneelastzone | -0,012 | annähernde Symmetrie | - |
| Sonnenscheindauer | -0,239 | annähernde Symmetrie | - |
| Temperatur | -0,972 | mäßige Schiefe | - |
| Windlastzone | 0,507 | mäßige Schiefe | - |
| Zerfallsrate | 0,142 | annähernde Symmetrie | - |

Die Kurtosis der Verteilungen der Parameter des zusammengesetzten Datensatzes kann der Tabelle 32 entnommen werden.

Tabelle 32: Kurtosis der Parameter im zusammengesetzten Datensatz (SPSS) (Quelle: eigene Darstellung)

| Parameter | Kurtosis nach SPSS | Bewertung nach George und Mallery [168] | Bewertung nach Hair [166] |
|-------------------|--------------------|---|----------------------------------|
| Alter | -1,205 | Normalverteilung | - |
| Baujahr | -1,214 | Normalverteilung | - |
| Erschütterung | -1,327 | Normalverteilung | - |
| Frosttage | -0,678 | Normalverteilung | (Normalverteilung) ⁶⁸ |
| Hagelzone | -1,039 | Normalverteilung | - |
| Niederschlag | -1,501 | Normalverteilung | - |
| Schneelastzone | -2,0 | - | - |
| Sonnenscheindauer | -1,067 | Normalverteilung | - |
| Temperatur | -0,821 | Normalverteilung | Normalverteilung |
| Windlastzone | -1,358 | Normalverteilung | - |
| Zerfallsrate | 0,564 | Normalverteilung | Normalverteilung |

Die graphischen Darstellungen der Verteilungen in der Form von Histogrammen sind im Anhang B enthalten.

8.4 Grafische Datenanalyse

In den Grundlagenkapiteln (vgl. Kapitel 2) dieser Arbeit wurde bereits darauf hingewiesen, dass eine klare Differenzierung zwischen den verschiedenen Skalenniveaus von Features bei der Datenaufbereitung von entscheidender Bedeutung ist. Insbesondere während der graphischen Datenanalyse, die ein integraler Bestandteil der Explorationsphase ist, ist es unerlässlich, das Skalenniveau der Features zu kennen, um eine geeignete Analyseverfahren wählen zu können.

Differenziert wird zwischen kategorialen Daten (Nominalskala, Ordinalskala) und metrischen Daten (Intervallskala, Ratioskala/Verhältnisskala).

Nominale Skala: Die Daten werden in nicht-numerische Kategorien eingeteilt, wobei die Reihenfolge keine Rolle spielt.

Ordinalskala: Bei der Ordinalskala werden die Daten wie bei der Nominalskala in Kategorien eingeteilt, aber die Reihenfolge ist wichtig.

⁶⁸ Unter der Berücksichtigung der Kurtosis von -1,130 sind die Frosttage nach der Definition von Hair nicht normalverteilt.

Intervallskala: Die metrischen Daten haben eine Ordnung, messbare Abstände, aber keinen natürlichen Nullpunkt (ggf. einen willkürlichen Nullpunkt).

Ratio- oder Verhältnisskala: Die Daten haben eine eindeutige Ordnung, messbare Abstände und einen natürlichen Nullpunkt.

Tabelle 33: Skalenniveaus der verwendeten Parameter (Quelle: eigene Darstellung)

| Parameter | Skalenniveau |
|-----------------------------------|---------------------------|
| Alter [Jahre] | Metrisch (Ratioskala) |
| Baujahr [-] | Metrisch (Intervallskala) |
| Erschütterung [m/s ²] | Metrisch (Intervallskala) |
| Frosttage [-] | Metrisch (Intervallskala) |
| Hagelzone [-] | Kategorial (Ordinal) |
| Niederschlag [mm] | Metrisch (Intervallskala) |
| Schneelastzone [-] | Kategorial (Ordinal) |
| Sonnenscheindauer [h] | Metrisch (Intervallskala) |
| Temperatur [C°] | Metrisch (Intervallskala) |
| Windlastzone [-] | Kategorial (Ordinal) |
| Zerfallsrate [-] | Metrisch (Intervallskala) |

Zur grafischen Darstellung von Zusammenhängen werden in der Statistik üblicherweise Korrelationsmatrizen verwendet. Dabei ist zu beachten, dass eine Korrelation nicht notwendigerweise bedeutet, dass auch eine Kausalität vorliegt. In der Datenanalyse des maschinellen Lernens werden üblicherweise die folgenden drei Korrelationskoeffizienten verwendet: Den Bravais-Pearson-Korrelationskoeffizienten, den Kendall- (Rang-) Korrelationskoeffizienten (Kendalls Tau⁶⁹) oder den Spearman-(Rang-) Korrelationskoeffizienten (Spearmans Rho).

Bravais-Pearson misst die lineare Korrelation zwischen zwei metrischen Variablen, ist aber sehr empfindlich gegenüber Ausreißern [169]. Bravais-Pearson setzt dabei voraus, dass mindestens eine Variable normalverteilt ist [170].

Kendall und Spearman berechnen die Rangkorrelation zwischen zwei ordinalen Variablen, zwei metrischen Variablen oder einer metrischen und einer ordinalen Variable. Dabei können sowohl Spearman als auch Kendall nichtlineare Korrelationen abbilden, beurteilt werden aber ausschließlich monotone Beziehungen.

⁶⁹ Bei der Berechnung von Kendalls Tau wird zwischen Tau-a, Tau-b und Tau-c differenziert. In dieser Arbeit handelt es sich bei Kendalls Tau ausschließlich um Kendalls Tau-b.

Sowohl Kendall als auch Spearman sind nicht so stark sensitiv bei Ausreißern wie Bravais-Pearson, wobei Kendall als robuster gegenüber Ausreißern und kleinen Datensätzen gilt als Spearman [171].

Bei der Analyse einer metrischen Variablen berücksichtigen Kendall und Spearman ausschließlich die Rangwerte der metrischen Variable und nicht deren eigentlicher numerischer Wert, wodurch je nach Datenverteilung Verzerrungen durch diese Transformation (Rangtransformation) entstehen können.

Um solche Verzerrungen bei der Analyse von metrischen und ordinalen Variablen zu minimieren, wurde vor der Korrelationsanalyse in Excel eine Transformation der metrischen Zerfallsraten in eine ordinale Variable durchgeführt. Dazu wurde für jede Kostengruppe eine eigene Formel geschrieben, um die Zerfallsraten entsprechend ihrer Position im Datensatz in die Ränge von 1 bis 12 zu transformieren. Durch dieses Vorgehen wurde eine geeignete Grundlage geschaffen, um die Korrelationen zwischen den ordinalen Variablen und der metrischen Zerfallsrate effektiv zu analysieren.

An dem Beispiel der KG 3310 bei einer minimalen Zerfallsrate von 0,5 und einer maximalen Zerfallsrate von 2,25 sieht die Formel für die Transformation der metrischen Daten zu einer Ordinalskala folgendermaßen aus (vgl. 8.2):

```
= WENN([Zerfallsrate]<=0.6667; 1; WENN([Zerfallsrate]<=0.8333; 2; WENN([Zerfallsrate]<=1; 3; WENN([Zerfallsrate]<=1.1667; 4; WENN([Zerfallsrate]<=1.3333; 5; WENN([Zerfallsrate]<=1.5; 6; WENN([Zerfallsrate]<=1.6667; 7; WENN([Zerfallsrate]<=1.8333; 8; WENN([Zerfallsrate]<=2; 9; WENN([Zerfallsrate]<=2.1667; 10; WENN([Zerfallsrate]<=2.3333; 11; 12 )))))))))))
```

Für die grafische Datenanalyse in diesem Kapitel wurden für alle Datensätze Korrelationsmatrizen mit dem Bravais-Pearson-Korrelationskoeffizienten und dem Kendall-Korrelationskoeffizienten erstellt. Aufgrund der Robustheit bei kleineren Datensätzen wurde für die Beziehungen der ordinalen Daten der Kendall-Korrelationskoeffizient anstatt des Spearman-Korrelationskoeffizienten gewählt.

Der Korrelationskoeffizient dieser Matrizen ist dabei ein quantitatives Maß zur Beurteilung der Stärke und Richtung der Beziehung zwischen den beiden stetigen Variablen und beschreibt die lineare Korrelation (Bravais-Pearson) bzw. monotone Korrelation (Kendall, Spearman). Der Korrelationskoeffizient kann Werte zwischen -1 und +1 annehmen. Bei einem Wert von +1 (oder -1) besteht eine vollständig positive (oder negative) Beziehung zwischen den betrachteten Variablen.

Dieser Korrelationskoeffizient erfasst ausschließlich die bivariate Korrelation und liefert keine Aussage darüber, ob ein Tupel aus zwei oder mehr Variablen in Korrelation zu einer spezifischen dritten Variable steht (multivariate Korrelation).

Das in den Kapiteln 9.1 und 9.3 entwickelte neuronale Modell ist dagegen in der Lage, solche multivariate Korrelation zu identifizieren.

Für die Interpretation der Korrelationskoeffizient hat sich in der Wissenschaft der Standard von Cohen [172] etabliert. Cohen definiert folgende Richtwerte (vgl. Tabelle 34) für die Interpretation des Korrelationskoeffizient r :

Tabelle 34: Interpretation des Korrelationskoeffizienten r nach Cohen (Quelle: eigene Darstellung nach [172])

| Interpretation | Korrelationskoeffizient |
|----------------------|-------------------------|
| nicht signifikant | $r \leq 0,1 $ |
| schwache Korrelation | $r > 0,1 $ |
| mittlere Korrelation | $r > 0,3 $ |
| starke Korrelation | $r > 0,5 $ |

Für die Interpretation der Koeffizienten wird in diesem Kapitel der Standard von Cohen verwendet.

Die vollständigen grafischen Auswertungen finden sich in Anhang B und Anhang C dieser Arbeit. In diesem Kapitel werden am Beispiel der tragenden Außenwand (KG 3310) der Aufbau und die Interpretation der Korrelationsmatrix erläutert.

Eine zusammenfassende Interpretation der Ergebnisse findet sich im Kapitel 10.

Die Korrelationsmatrizen wurden mit Hilfe der Pandas-Bibliothek grafisch als sogenannte Heatmaps dargestellt.

Der Schwerpunkt liegt auf der Analyse der Korrelation zwischen den Einflussfaktoren und der Zerfallsrate (vgl. Kapitel 9.2.5). Der Koeffizient in der ersten Spalte von rechts wird verwendet, um die Korrelation zwischen dem Parameter in der entsprechenden Zeile und der Zerfallsrate zu bewerten.

Gemäß Abbildung 79 liegt eine bivariate lineare Korrelation zwischen der Temperatur und der Zerfallsrate mit der Stärke 0,41 vor. Es handelt sich damit um eine positive mittlere Korrelation. Positiv heißt in diesem Fall, dass eine steigende Temperatur („Temp“ in der Abbildung 79) mit einer steigenden Zerfallsrate korreliert.

Aufgrund der Normalverteilung der Zerfallsrate sind für die Analyse zweier metrischer Variablen auch alle Voraussetzung für den Einsatz von Bravais-Pearson erfüllt.




Abbildung 79: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3310 (Quelle: eigene Darstellung)

Betrachtet man ergänzend die Kendall-Korrelationskoeffizienten-Matrix (vgl. Abbildung 80), wird die These gestützt, dass eine bivariate Korrelation zwischen der Temperatur und der Zerfallsrate vorliegt.




Abbildung 80: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3310 (Quelle: eigene Darstellung)

Nach Kendall beträgt die Stärke 0,58, d.h., es handelt sich um eine starke positive Korrelation. Der höhere Wert bei Kendall zeigt an, dass die Korrelation nicht streng linear, sondern nur monoton ist. Das heißt übertragen auf das Bauelement, dass die tragende Außenwand bei höherer Temperatur schneller das Ende ihrer Lebensdauer erreicht.

Relevante Auswirkungen (starke Korrelation) auf die Lebensdauer der tragenden Außenwand haben nach den Matrizen: die Temperatur, der Niederschlag, die Schneelastzone und die Erschütterung.

Inwieweit eine Kombination aus verschiedenen Einflüssen wie beispielsweise die Anzahl der Frosttage und der Niederschlag einen Einfluss auf die Zerfallsrate haben wird in der bivariaten Analyse nicht berücksichtigt.

Auffallend ist, dass eine starke negative Korrelation zwischen der Erschütterung und der Zerfallsrate besteht. Dies bedeutet, dass in einem Gebiet mit vielen Erschütterungen die Lebensdauer einer tragenden Außenwand höher ist als in einem Gebiet mit weniger Erschütterungen.

Aufgrund der Tatsache, dass eine Korrelation allein nicht zwangsläufig auf eine Kausalität hindeutet, liegt die Vermutung nahe, dass der Zusammenhang möglicherweise darauf beruht, dass tragende Außenwände in Erdbebenzonen eine durchschnittlich höhere Lebensdauer aufweisen, da diese Gebäude aufgrund erhöhter Anforderungen an ihre Stabilität tendenziell robuster gebaut sind. Die besonderen Anforderungen an Gebäude in Erdbebenzonen sind in der DIN EN 1998-1/NA:2021-07 [124] definiert. Darüber hinaus ist zu beachten, dass die geringe Anzahl der variierten Standorte die Möglichkeit in sich birgt, dass die beobachtete Korrelation zufällig ist und keine signifikante Relevanz hat.

9 Modellentwicklung

9.1 Einleitung

Die Entwicklung des Modells wird in die drei Kapitel „Theoretisches Modell“ (vgl. 9.2), „Neuronales Modell“ (vgl. 9.3) und „Prototyp“ (vgl. Kapitel 9.4) unterteilt.

Das Kapitel "Theoretisches Modell" behandelt das theoretische Konzept. Im Kapitel "Neuronales Modell" wird die zentrale Komponente dieses Konzepts, das neuronale Modell, ausführlich dargestellt. Im letzten Kapitel wird der Prototyp erläutert.

9.2 Theoretisches Modell

9.2.1 Einleitung

Gegenstand dieses Kapitels ist die Darstellung und Erläuterung des theoretischen Modells, das als Grundlage für die Erstellung des Prototyps dient. Aufgrund ihrer Bedeutung wird in diesem Kapitel in einem spezifischen Unterkapitel auf die theoretische Untersuchung der Zerfallsrate eingegangen.

In der Abbildung 81 ist das theoretische Modell, untergliedert in vier Komponenten, dargestellt:

- **Komponente A:** Nutzereingabe über ein Webinterface,
- **Komponente B:** Zuordnung der Einflussfaktoren über eine Datenbank,
- **Komponente C:** Ermittlung der Zerfallsrate über ein neuronales Modell,
- **Komponente D:** Ausgabe des Abnutzungsvorrates über eine grafische Benutzeroberfläche.

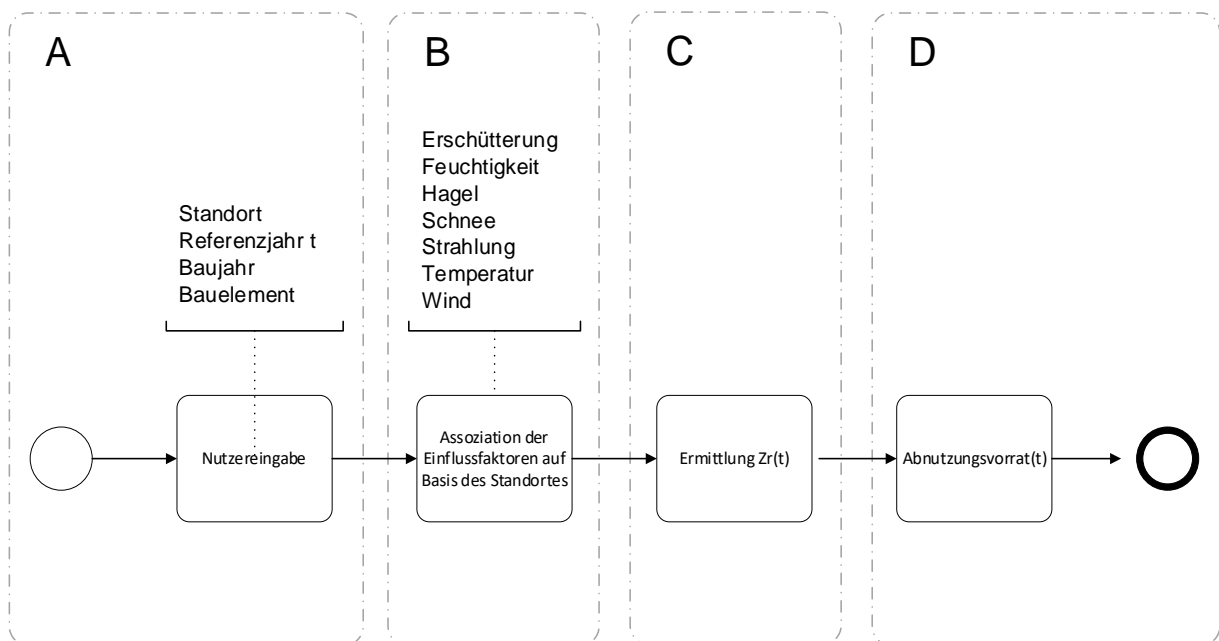


Abbildung 81: Prozessdarstellung (BPMN) für das theoretische Modell des Prototyps (Quelle: eigene Darstellung)

Die Komponente C wird aufgrund ihrer Relevanz für diese Arbeit gesondert in Kapitel 9.3 erläutert. Die Komponenten A, B und D werden in diesem Kapitel auf theoretischer Basis behandelt, während ihre praktische Umsetzung im Kapitel 9.4 thematisiert wird.

9.2.2 Komponenten A und B

Auf Basis der allgemeinen Gebäudedaten, welche sich aus dem Standort und dem Baujahr bzw. dem Einbaujahr des Bauteiles zusammensetzen, soll für ein spezifisches Bauelement die Zerfallsrate zu einem Referenzjahr t bestimmt werden.

Über den Standort werden dabei die entsprechenden Einflussfaktoren ermittelt, so dass der Benutzer keine Informationen über die spezifischen Einflussfaktoren des Standortes besitzen muss (vgl. Tabelle 35).

Tabelle 35: Ermittlung der Zerfallsrate über Nutzereingabe und die assoziierten Einflussfaktoren am Standort (Quelle: eigene Darstellung)

| Nutzereingabe | Ermittelt über den <u>Standort (PLZ)</u> |
|--|--|
| <ul style="list-style-type: none"> ▪ Allgemeine Gebäudedaten <ul style="list-style-type: none"> ○ <u>Standort (PLZ)</u> ○ Baujahr (bzw. Einbaujahr) ○ Referenzjahr t (bzw. Bauteilalter) ▪ Bauelement (z.B. 331(0)) | <ul style="list-style-type: none"> ▪ Einflussfaktoren <ul style="list-style-type: none"> ○ Erschütterung ○ Feuchtigkeit ○ Hagel ○ usw. |

Die Verbindung zwischen dem Standort und dem Datensatz mit den spezifischen Einflussfaktoren erfolgt über die Postleitzahl.

9.2.3 Komponente C

Die Ermittlung der Zerfallsrate erfolgt über das neuronale Modell (vgl. Kapitel 9.3).

9.2.4 Komponente D

Über die in der Komponente C durch das neuronale Modell ermittelte Zerfallsrate wird in der Komponente D für die Nutzerausgabe der Abnutzungsvorrat für ein entsprechendes Referenzjahr t berechnet. Der mathematische Zusammenhang zwischen der Zerfallsrate, dem Abnutzungsvorrat und dem Bauteilalter ist in der Formel 9.1 abgebildet.

$$Abnutzungsvorrat(t) = (100 - (Zr(t) \times Bauteilalter)) \quad 9.1$$

In dem folgenden Kapitel wird die Zerfallsrate noch einmal ausführlich mit einem Beispiel erläutert.

9.2.5 Zerfallsrate

Die Zerfallsrate $Zr(t)$ wird dabei nach Formel 9.2 definiert.

$$Zr(t) = \frac{100 - \text{Abnutzungsvorrat}(t)}{\text{Referenzjahr } t - \text{Einbaujahr}} \quad 9.2$$

$$Zr(t) = \frac{100 - \text{Abnutzungsvorrat}(t)}{\text{Bauteilalter } (t)} \quad 9.3$$

Das Bauteilalter zum Zeitpunkt t entspricht dabei der Differenz zwischen dem Referenzjahr und dem Einbaujahr (vgl. Formel 9.3).

Beispiel: Ein Bauelement, welches im Jahr 2017 verbaut wurde, weist bei einer Inspektion 2020 (Referenzjahr) einen Abnutzungsvorrat von noch 93 % auf. Das Alter des Bauteiles betrug bei der Inspektion im Jahr 2020 damit 3 Jahre. Folglich lag die Zerfallsrate (2020) für das Bauteil bei 2,33.

Das Bauteil in diesem Beispiel hat 2,33 % des Abnutzungsvorrates pro Jahr bis zum Zeitpunkt t verloren. Die Zerfallsrate zum Zeitpunkt t beschreibt damit den prozentualen Abbau des Abnutzungsvorrates pro Jahr bis zum Zeitpunkt t . Wie in der Abbildung 82 dargestellt ist, wird der nichtlineare Verlauf des Abbaus des Abnutzungsvorrates (graue gestrichelte Linie) des Bauteiles in viele lineare Teilabschnitt segmentiert.




Abbildung 82: Illustration der Zerfallsrate zu verschiedenen Zeitpunkten des nicht linearen Abbaus des Abnutzungsvorrates eines Bauelementes (Quelle: eigene Darstellung)

Die Zerfallsrate beschreibt damit zwar die durchschnittliche Zerfallsrate pro Jahr bis zum Zeitpunkt t , darf aber nicht als linearen Zerfall bis zu diesem Zeitpunkt betrachtet werden. In früheren und späteren Abschnitten kann die Zerfallsrate niedriger oder höher sein, wie in der Abbildung 82 dargestellt ist.

9.3 Neuronales Modell

9.3.1 Einleitung

Das Herstellen des Zusammenhanges des Abnutzungsvorrates zu einem spezifischen Zeitpunkt (abhängige Variable) zu den Einflussfaktoren (unabhängige Variablen) wird als Regressionsproblem bezeichnet. Weil der Abbau des Abnutzungsvorrats nicht linear verläuft bzw. die Abhängigkeit zwischen der abhängigen Variablen und den unabhängigen Variablen nicht linear ist, handelt es sich um ein nichtlineares Regressionsproblem.

Nichtlineare Regressionsprobleme können mit Hilfe von Algorithmen des maschinellen Lernens gelöst werden, wenn eine ausreichend große Datenbasis zur Verfügung steht. Bei einer großen Menge bereits beschrifteter (vgl. Kapitel 8.2.8) Daten bietet sich die Methode des überwachten Lernens an.

Ziel ist es, das neuronale Modell so zu trainieren, dass es ein Muster zwischen der Zerfallsrate und den Informationen aus der Tabelle 35 erkennt und auf dieser Basis unbekannte Zerfallsraten bestimmen kann. Das neuronale Modell soll mit den in der Tabelle 36 aufgelisteten Features trainiert werden. Diese werden mit der Zerfallsrate zum Zeitpunkt t ($Zr(t)$) beschriftet/ge-labelt. Der Datensatz für das Training des neuronalen Modells im Referenzjahr t ist das Jahr der Inspektion.

Hinweis: In der Terminologie des maschinellen Lernens wird das Label auch als Target (dt. Zielvariable) bezeichnet. In der Literatur findet man öfter den Begriff des Labels, im Programmiercode hingegen wird primär der Begriff Target verwendet.

Tabelle 36: Features und Label für das neuronale Modell (Quelle: eigene Darstellung)

| Features (dt.: Merkmale) | Label (dt. Beschriftung) |
|-------------------------------|--------------------------|
| 3310 | $Z_r(t)$ |
| (...) ⁷⁰ | |
| 3634 | |
| Baujahr/Einbaujahr | |
| Bauteilalter | |
| Erschütterung am Standort | |
| Feuchtigkeit am Standort | |
| Hagel am Standort | |
| Schneelastzone am Standort | |
| Sonnenscheindauer am Standort | |
| Temperatur am Standort | |
| Windlastzone am Standort | |

Die Erstellung des neuronalen Modells erfolgte in der Programmiersprache Python unter der Verwendung der TensorFlow-Bibliothek sowie der Keras-Bibliothek.

Erläuterungen zu den Bibliotheken befinden sich in Kapitel 2.3.3.8.

In diesem Kapitel wird nicht im Detail auf den jeweiligen Quellcode eingegangen, sondern nur das Verfahren als solches erläutert. Relevante Auszüge aus dem Code sind im Anhang beigefügt und werden an den entsprechenden Stellen zitiert.

Der Prozessablauf ist in der Spezifikationssprache BPMN⁷¹ in den beiden folgenden Abbildungen als BPD⁷² dargestellt (Abbildung 83, Abbildung 84), der vollständige Prozess ist im Anhang A 8 zu finden.

⁷⁰ Zu Gunsten der Übersichtlichkeit werden an dieser Stelle nicht alle Kostengruppen aufgelistet.

⁷¹ Business Process Model and Notation, ist ein Standard für die Modellierung von (Geschäfts)prozessen. Die dabei erstellten Diagramme heißen BPD (Business Process Diagram).

⁷² Business Process Diagram (dt.: Geschäftsprozessdiagramm)




Abbildung 83: Prozessablaufdiagramm Erstellen des neuronalen Modelles (Teil 1) (Quelle: eigene Darstellung)




Abbildung 84: Prozessablaufdiagramm Erstellen des neuronalen Modelles (Teil 2) (Quelle: eigene Darstellung)

Für ein besseres Verständnis wurde der Prozess inhaltlich in drei Abschnitte unterteilt. Die folgenden Kapitel sind entsprechend dieser Gliederung strukturiert und erläutern die jeweiligen Prozessabschnitte. Das Kapitel zur Datenvorbereitung (vgl. Kapitel 9.3.2) beschreibt den Prozess der Datenpräparation vor dem eigentlichen Training des Modells. Im folgenden Abschnitt (Kapitel 9.3.3) wird die Architektur des Modells zusammen mit den entsprechenden Hyperparametern für das Training erläutert. Im abschließenden Abschnitt (vgl. Kapitel 9.3.4) werden die Ergebnisse des Trainings evaluiert und die Konvertierung des endgültigen Modells behandelt.

9.3.2 Datenvorbereitung

Der Prozess startet mit dem Laden der CSV-Datei, die Funktion *load_my_dataset* (vgl. Anhang D 1) öffnet die Datei *datase.csv*, liest die Daten ein und speichert sie als Bunch⁷³. Dabei werden die Features und das Label/Target aus der CSV-Datei extrahiert und in Arrays gespeichert. Das Bunch-Objekt enthält diese gespeicherten Daten und die Namen der Merkmale und Zielvariable.

⁷³ Bunch ist ein Container in Python, der Schlüssel-Wert-Paare ähnlich einem Dictionary speichert.

Nach dem Laden der Datei werden die Features an die Variable x gehängt und die Labels/Targets an die Variable y .

Aus den Daten von x wird ein *pandas DataFrame*⁷⁴ erstellt, bei dem die Spalten den Namen der Features entsprechend und die Spalten die Daten von x enthalten. Danach wird eine zusätzliche Spalte mit dem Namen des Labels/Targets hinzugefügt und die Spalte mit den Daten von y gefüllt.

Ein Ausschnitt dieses DataFrames ist in der Abbildung 85 dargestellt.

| | Temp | Niederschlag | Sonnenscheindauer | Windlastzone | Schneelastzone | Erschütterung | Hagelzone | Frosttage | 3310 | 3341 | ... | 3634 | Alter | Baujahr | Zerfallsrate |
|------|------|--------------|-------------------|--------------|----------------|---------------|-----------|-----------|------|------|-----|------|-------|---------|--------------|
| 1710 | 10.9 | 711.9 | 1734.2 | 1.0 | 2.0 | 0.5 | 15.0 | 62.6 | 0.0 | 0.0 | ... | 0.0 | 45.0 | 1975.0 | 1.639300 |
| 2541 | 10.9 | 690.0 | 1652.0 | 1.5 | 2.0 | 0.3 | 7.5 | 62.9 | 0.0 | 1.0 | ... | 0.0 | 45.0 | 1973.0 | 1.853900 |
| 873 | 10.8 | 585.0 | 1675.5 | 1.0 | 1.0 | 1.0 | 10.0 | 51.8 | 0.0 | 0.0 | ... | 0.0 | 23.0 | 1995.0 | 1.371500 |
| 2461 | 10.5 | 633.3 | 1575.0 | 2.0 | 1.0 | 1.6 | 7.5 | 63.8 | 0.0 | 1.0 | ... | 0.0 | 35.0 | 1985.0 | 2.142857 |
| 2953 | 10.8 | 585.0 | 1675.5 | 1.0 | 1.0 | 1.0 | 10.0 | 51.8 | 1.0 | 0.0 | ... | 0.0 | 46.0 | 1972.0 | 0.845800 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |

Abbildung 85: Ausschnitte Panas DataFrame (Quelle: eigene Darstellung)

Auf der Grundlage dieses DataFrames wurden alle grafischen Analysen durchgeführt, die nicht direkt in SPSS durchgeführt wurden. Dazu gehören u.a. die Erstellung von Histogrammen sowie die Berechnung und Darstellung von Korrelationsmatrizen. Diese grafische Analyse ist optional und nicht notwendig, um das neuronale Modell zu erstellen.

Anschließend werden die Features in kategoriale und metrische Features unterteilt. Die metrischen Features werden dann mit dem scikit-learn StandardScaler normalisiert bzw. standardisiert.

Die Entscheidung für die Verwendung des StandardScalers basiert auf der Empfehlung der ISO/IEC 23053:2022 [59], die den StandardScaler, den Min-Max-Scaler oder den DecimalScaler als geeignete Skalierungsmethoden empfiehlt. ISO/IEC 23053:2022 [80] stellt diese Skalierungsmethoden als mögliche Optionen dar, um eine geeignete Datenaufbereitung für maschinelles Lernen zu gewährleisten. Bei den Testläufen mit diesen drei Skalierungsmethoden konnte mit dem StandardScaler während des Trainingsprozesses die höchste Genauigkeit erzielt werden.

Auf eine Normalisierung oder Standardisierung der kategorialen Merkmale wird dagegen verzichtet. Dieser Verzicht ergibt sich aus der Natur kategorialer Merkmale, da sie diskrete Kategorien und keine numerischen Werte darstellen. Die Anwendung der Normalisierung/Standardisierung auf kategoriale Merkmale wäre daher nicht zielführend, da sie die inhaltliche Bedeutung der Kategorien verfälschen und zu verzerrten Resultaten führen könnte. Die behandelten metrischen Features und die unbehandelten kategorialen Features werden nach diesem Schritt in einem einzelnen eindimensionalen Array zusammengeführt und an die Variable X gehangen. Einen Auszug aus dem Programmiercode finden Sie im Anhang D 2.

⁷⁴ Ein pandas DataFrame ist eine tabellarische Datenstruktur in Python, die Daten in Zeilen und Spalten organisiert und eine Vielzahl von Funktionen zur Datenanalyse und -manipulation bietet. Die Programmierbibliothek pandas ist in Kapitel 2.3.3.8 erläutert.

Die Parameter, die der StandardScaler für die Z-Transformation verwendet hat, werden im Format JSON abgespeichert (vgl. Anhang D 3).

In den nächsten beiden Schritten werden aus den Feature-Daten (X) und die Label/Target-Daten (y) die Trainingsdatensätze, Testdatensätze und Validierungsdatensätze erzeugt. Dazu werden zunächst die Daten X und y im Verhältnis 4:1 in Trainingsdaten und Testdaten aufgeteilt und anschließend die Trainingsdaten ebenfalls im Verhältnis 4:1 in Trainingsdaten und Validierungsdaten. Aufteilungen von 80:20 sind in der Praxis übliche Verhältnisse, die in der Abhängigkeit der Größe des Datensatzes nach oben oder unten angepasst werden (70:30 bzw. 90:10) [173–175]. Um die Reproduzierbarkeit der Ergebnisse und Vergleichbarkeit von unterschiedlichen Trainingsläufen zu gewährleisten, wird bei beiden Aufteilungen der Parameter *random_state* mit dem Wert 1 übergeben, um eine nicht-deterministische Aufteilung zu verhindern.

9.3.3 Architektur

Nach dem Vorbereiten der Daten und dem Aufteilen in Trainingsdaten, Testdaten und Validierungsdaten wird das sequenzielle neuronale Modell mit den Hyperparametern initialisiert. Die Architektur kann dem Python-Code in der Abbildung 86 entnommen werden.

```
#Neural Network Architecture
model = Sequential()
model.add(Dense(units=91, activation='relu', input_shape=(20,)))
model.add(Dense(units=62, activation='relu'))
model.add(Dense(units=44, activation='relu'))
model.add(Dense(units=21, activation='relu'))
model.add(Dense(units=79, activation='relu'))
model.add(Dense(units=1))

#Optimizer
opt = keras.optimizers.Adam(learning_rate=0.0015858034769032404)

#compile
model.compile(optimizer=opt, loss='mean_absolute_percentage_error', metrics=[
    'mean_absolute_percentage_error'])

#fit
history = model.fit(X_train, y_train, epochs=150, batch_size=15,
    validation_data=(X_val, y_val))
```

Abbildung 86: Architektur des neuronalen Netzwerkes (Quellen: eigene Darstellung)

Das Modell besteht aus insgesamt sechs (trainierbare) Schichten (Layers):

- Eingabeschicht (Input Layer): Diese Schicht hat 20 Eingangsneuronen, die der Größe der Eingabedaten entsprechen. Es wird eine lineare Aktivierungsfunktion (Identitätsfunktion) verwendet.
- Versteckte Schicht (Hidden Layer) 1: Diese Schicht hat 91 Neuronen und verwendet die ReLU-Aktivierungsfunktion.

- Versteckte Schicht (Hidden Layer) 2: Diese Schicht hat 62 Neuronen und verwendet die ReLU-Aktivierungsfunktion.
- Versteckte Schicht (Hidden Layer) 3: Diese Schicht hat 44 Neuronen und verwendet die ReLU-Aktivierungsfunktion.
- Versteckte Schicht (Hidden Layer) 4: Diese Schicht hat 21 Neuronen und verwendet die ReLU-Aktivierungsfunktion.
- Versteckte Schicht (Hidden Layer) 5: Diese Schicht hat 79 Neuronen und verwendet die ReLU-Aktivierungsfunktion.
- Ausgabeschicht (Output Layer): Diese Schicht hat 1 Ausgangsneuron und verwendet die lineare Aktivierungsfunktion (Identitätsfunktion).

Als Optimizer wird der Adam-Optimizer (Adaptive Moment Estimation) eingesetzt.

In dieser Arbeit wird nicht im Detail auf die Funktionsweise der Optimizer eingegangen, da der Schwerpunkt auf der allgemeinen Funktionsweise von neuronalen Modellen liegt und nicht auf einer detaillierten Erklärung jeder einzelnen technischen Komponente. Die Komplexität der Optimizer erfordern eine umfangreiche Behandlung, die den Rahmen dieser Arbeit übersteigen würde. Es gibt jedoch neben dem Adam-Optimizer eine Vielzahl von weiteren Optimizern, die je nach Architektur des neuronalen Netzes, Datensatzgröße, Konvergenzanforderungen, Modellkomplexität und spezifischer Problemstellung eine verbesserte Leistung bieten können.

Für dieses Modell konnte mit dem Adam-Optimizer die größte Genauigkeit erreicht werden, getestet wurden alle Optimizer der Keras-Bibliothek. Weitere Informationen zu Optimizern finden Sie in der Keras-Dokumentation im Kapitel Optimizers [176].

In allen Schichten wird die ReLU-Funktion (Rectified Linear Unit) als Aktivierungsfunktion verwendet. Diese Entscheidung beruht auf der effizienten Berechnung, der Vermeidung des „Verschwindens des Gradienten“⁷⁵ und der Fähigkeit, komplexe nichtlineare Beziehungen in den Daten zu erfassen.

In der Anfangsphase wurde der Trainingsverlust durch die Verlustfunktion "mean_squared_error" (MSE) quantifiziert, die den mittleren quadratischen Fehler zwischen den Vorhersagen und den tatsächlichen Werten berechnet. Im weiteren Verlauf wurde die Verlustfunktion durch den "mean_absolute_percentage_error" (MAPE), den absoluten prozentualen Fehler, ersetzt. Der MAPE erbrachte in der Trainingsphase bei der vorliegenden Datengrundlage eine wesentlich höhere Leistung, weil dieser nicht so empfindlich auf Ausreißer reagiert wie der MSE.

Die Leistung des Modelles auf die Testdaten bzw. Validierungsdaten wird ebenfalls mit der Metrik MAPE evaluiert.

Verwendet werden folgende Hyperparameter:

- `learning_rate = 0.0015858034769032404`,

⁷⁵ Das Verschwinden des Gradienten ist ein Problem beim Training des neuronalen Modelles, bei dem durch zu kleine Ableitungen bestimmter Aktivierungsfunktionen die Neuronen in tiefen Schichten kaum mehr Wissen dazugewinnen und dadurch der Lernprozess sehr lange dauert.

- epochs = 150,
- batch_size = 15.

(Eine Erläuterung der Begriffe befinden sich in dem Kapitel 2.3.3.7)

In der Anfangsphase wurde für die Erstellung des neuronalen Modells eine iterative Methode, bekannt als "Versuch und Irrtum" (engl.: Trial-and-Error), verwendet, um die optimale Netzwerkarchitektur in Verbindung mit den entsprechenden Hyperparametern zu finden. Dieser Ansatz basierte darauf, verschiedene Kombinationen von Netzwerkarchitekturen und Hyperparametern auszuprobieren und die Leistung des Modells durch wiederholtes Testen zu evaluieren.

Obwohl mit diesem Ansatz ein Netz mit akzeptabler Leistung⁷⁶ erzeugt werden konnte, war die Suche nach der optimalen Konfiguration aufgrund der vielen möglichen Kombinationen von Hyperparametern sehr zeitaufwendig und stand in keinem Verhältnis zur Leistungssteigerung.

Aus diesem Grund wurde für die abschließende Leistungsoptimierung auf die Verwendung der KerasTuner-Bibliothek [111] zurückgegriffen.

9.3.3.1 KerasTuner

Durch die Verwendung der KerasTuner-Bibliothek konnte der Zeitaufwand für die Optimierung erheblich reduziert werden, da nicht mehr jede Kombination manuell getestet werden musste. Stattdessen nutzte das Modell die verfügbaren Daten, um die Suche nach den besten Hyperparametern effizienter zu gestalten.

Dem KerasTuner wurden folgende Randbedingungen⁷⁷ für die Suche nach dem bestmöglichen Modell vorgegeben:

- Batch-Größe: 5, 8, 10, 12, 20, 25,
- Dense-Schichten: 16 - 256 Neuronen, Aktivierungsfunktion RELU,
- Epochen: 150,
- Ausführungen pro Durchlauf: 5,
- Anzahl der Schichten: 3 bis 7,
- Lernrate: 0.001 bis 0.01,
- Verlustfunktion: Mean Absolute Percentage Error (MAPE),
- Maximale Durchläufe (max_trials): 50,
- Bewertungsmetrik: Mean Absolute Percentage Error (MAPE),
- Optimierungsziel: Mean Absolute Percentage Error (MAPE).

⁷⁶ Auf die Bewertung der Leistung eines neuronalen Modelles wird im späteren Verlauf dieses Kapitels näher eingegangen.

⁷⁷ Bei diesen Randbedingungen handelt es sich um die verwendeten Randbedingungen, die in einer Vielzahl von Durchläufen iterativ weiter eingeschränkt wurden.

Eingesetzt wurde die *RandomSearch*-Methode, um die Konstellation mit dem geringsten absoluten prozentualen Fehler zu finden. Der Python-Code befindet sich im Anhang D 5.

Die Ergebnisse des KerasTuner (vgl. Abbildung 87) wurden als Grundlage für die Erstellung der Netzwerkarchitektur (vgl. Abbildung 86) verwendet.

```
Best mean_absolute_percentage_error So Far: 9.209018421173096
Total elapsed time: 7h 21m 40s
Model: "sequential_1"
```

| Layer (type) | Output Shape | Param # |
|------------------|--------------|---------|
| dense_5 (Dense) | (None, 91) | 1911 |
| dense_6 (Dense) | (None, 62) | 5704 |
| dense_7 (Dense) | (None, 44) | 2772 |
| dense_8 (Dense) | (None, 21) | 945 |
| dense_9 (Dense) | (None, 79) | 1738 |
| dense_10 (Dense) | (None, 1) | 80 |

```
=====  
Total params: 13,150  
Trainable params: 13,150  
Non-trainable params: 0
```

```
{'num_layers': 5, 'units_0': 91, 'units_1': 62, 'units_2': 44, 'lr':  
0.0015858034769032404, 'batch_size': 15, 'units_3': 21, 'units_4': 79}
```

Abbildung 87: Ergebnis KerasTuner (Quelle: eigene Darstellung)

9.3.4 Evaluation

In der Evaluationsphase wird überprüft, ob das Modell die angestrebte Prognosegenauigkeit erreicht hat. Die Genauigkeit hängt von den spezifischen Anforderungen des Anwendungsfalls und den verfügbaren Daten ab. Falls nach dem Training keine zufriedenstellende Genauigkeit erzielt wurde, werden die Hyperparameter angepasst und das Training erneut durchgeführt. Sollte selbst nach diesen Anpassungen keine ausreichende Genauigkeit erreicht werden können, könnte dies auf eine unzureichende Datenbasis hinweisen.

Das beste Modell aus dem KerasTuner erzielte einen MAPE (Mean Absolute Percentage Error) von 9,21, was bedeutet, dass das Modell durchschnittlich einen prozentualen Fehler von ca. 9 % in seinen Vorhersagen aufweist.

Mit anderen Worten, die durchschnittliche Abweichung zwischen den Vorhersagen des Modells und den tatsächlichen Werten beträgt etwa ca. 9 %.

Die grafische Darstellung der Lernkurve (vgl. Abbildung 88) zeigt, dass der Validierungsverlust (engl.: Validation-Loss) und der Trainingsverlust (engl.: Training-Loss) sehr nahe beieinander liegen und gegen 9,0 konvergiert (vgl. Abbildung 88).

Das weist darauf hin, dass das Modell sowohl auf den Trainingsdaten als auch auf den Validierungsdaten eine gute Leistung erbracht hat und eine effektive Generalisierungsfähigkeit zeigt ohne Anzeichen von Overfitting (vgl. Kapitel 2.3.3.6) oder Underfitting (vgl. Kapitel 2.3.3.6).




Abbildung 88: Lernkurve des neuronalen Modelles (MAPE) (Quelle: eigene Darstellung)

Dieser Grad an Genauigkeit und Verallgemeinerungsfähigkeit deutet darauf hin, dass das Modell in der Lage ist, sich gut an neue, bisher nicht gesehene Daten anzupassen, ohne in Überanpassung oder Unteranpassung zu verfallen.

In der grafischen Darstellung (vgl. Abbildung 89) der vorhergesagten Werte und den tatsächlichen Werten (Testdatenset) wird deutlich, dass es eine geringe Anzahl an Vorhersagen gibt, die auch außerhalb der 9 % Abweichung liegen.

In der Abbildung 89 stellen die grün markierte und die blau markierte Linie die Grenzen der Abweichung dar, die bei 9 % liegen. Alle Vorhersagen, die innerhalb dieses Bereichs liegen, weisen eine Genauigkeit von mindestens 91 % auf.




Abbildung 89: Plot „Vorhersagen des Modells (Zerfallsrate) vs. Tatsächliche Werte (Zerfallsrate)“
(Quelle: eigene Darstellung)

Das Modell wurde mit einer Prognosegenauigkeit von 91 % als geeignet für den Einsatz im Prototyp bewertet.

Um es mit der JavaScript-TensorFlow-Bibliothek⁷⁸ im Prototypen verwenden zu können, muss das Modell von HDF5 nach JSON konvertiert werden. Die Konvertierung erfolgt über die Kommandozeile mithilfe des internen Konverters von TensorFlow (tensorflowjs_converters⁷⁹).

⁷⁸ TensorFlow.js tfjs@3.17.0.

⁷⁹ „tensorflowjs_converter --input_format=keras /dir/model.h5 /dir/tfjs_model“.

9.4 Prototyp

Der Prototyp dient als graphische Schnittstelle zur Ansteuerung des AI-Modells, um über eine Benutzerschnittstelle standortspezifische Lebensdauerprognosen zu erstellen.

In diesem Zusammenhang bedeutet Lebensdauerprognose die Bestimmung der prozentualen Restlebensdauer zu einem bestimmten Zeitpunkt, d.h., wie viel Abnutzungsvorrat gemäß DIN 31051 [4] noch vorhanden ist.

Zu diesem Zweck wurde eine Benutzeroberfläche erstellt, in der der Benutzer die Lebensdauer für eine bestimmte Kostengruppe in Abhängigkeit von Alter, Baujahr und Standort (Postleitzahl) prognostizieren kann, dargestellt in der Abbildung 90.

Prognose über Standort

| Kostengruppe | Alter | Baujahr | PLZ |
|-----------------------------|-------|---------|-------|
| Tragende Außenwände (331) ▾ | 5 | 2018 | 66459 |

[prognostizieren](#)

Abbildung 90: Screenshot Benutzeroberfläche Prototyp (Prognose über Standort) (Quelle: eigene Darstellung)

Zusätzlich wurde eine weitere Benutzeroberfläche erstellt, bei der individuelle Einflussfaktoren an das KI-Modell übergeben werden. Diese zweite Variante, dargestellt in der Abbildung 91, ist notwendig, um die Einflüsse der Faktoren auf die Lebensdauer bewerten zu können. Die Auswertung der Einflüsse befindet sich in Kapitel 10.

Prognose über Einflussfaktoren

| Kostengruppe | Lufttemperatur | Niederschlag | Sonnenscheindauer | Windlastzone | Schneelastzone | Hagelzone | Erschütterung | Alter | Baujahr |
|----------------------------|----------------|--------------|-------------------|--------------|----------------|-----------|---------------|-------|---------|
| Tragende Außenwände (33) ▾ | 10,5 | 633,3 | 1575 | 2 | 1 | 7,5 | 1,6 | 25 | 1985 |

[prognostizieren](#)

Abbildung 91: Screenshot Benutzeroberfläche Prototyp (Prognose über Einflussfaktoren) (Quelle: eigene Darstellung)

Die Implementierung der Benutzeroberflächen erfolgte mit Hilfe der Programmiersprache HTML (HyperText Markup Language). Darüber hinaus wurden die Programmiersprachen PHP (Hypertext Preprocessor) und JS (JavaScript) verwendet.

Bei der Implementierung der Benutzeroberfläche wird das Open Source Frontend Framework Bootstrap⁸⁰ (Version 5.1.3) verwendet.

⁸⁰ Bootstrap ist ein Open-Source-CSS-Framework, das eine Sammlung (Bibliothek) von HTML-, CSS- und JavaScript-basierten Designvorlagen bietet.

Aufgrund der begrenzten Relevanz für die vorliegende Arbeit wird auf eine detaillierte Erläuterung aller programmiertechnischen Details verzichtet und stattdessen der Fokus auf die Darstellung des Workflows und den generellen Aufbau des Prototyps gelegt.

Zusätzlich zum Modell wurden die Parameter des StandardScalers im JSON-Format exportiert. Diese Parameter des StandardScalers erfüllen eine wichtige Funktion, indem sie sicherstellen, dass die Eingabedaten für die Prognose mit den gleichen Werten (Standardabweichung und Mittelwert) transformiert werden wie der Datensatz, der für das Modelltraining verwendet wurde. Dies wird durch die Z-Transformation der Daten erreicht.

Der Prozessablauf ist in Form von Flussdiagrammen in den Abbildung 92, Abbildung 93 und Abbildung 94 in vereinfachter Form grafisch dargestellt.




Abbildung 92: Prozessablaufdiagramm Restlebensdauer prognostizieren im Prototyp (Teil 1) (Quelle: eigene Darstellung)




Abbildung 93: Prozessablaufdiagramm Restlebensdauer prognostizieren im Prototyp (Teil 2) (Quelle: eigene Darstellung)




Abbildung 94: Prozessablaufdiagramm Restlebensdauer prognostizieren im Prototyp (Teil 3) (Quelle: eigene Darstellung)

Unabhängig davon, ob eine standort- oder einflussfaktorbasierte Prognose durchgeführt wird, wählt der Benutzer zu Beginn über ein Dropdown-Menü das entsprechende Bauteil aus, für das eine Lebensdauerprognose erstellt werden soll. Es werden nur die Kostengruppen zur Auswahl angeboten, für die das neuronale Modell trainiert wurde.

Die Auswahl ist in der Abbildung 95 dargestellt.

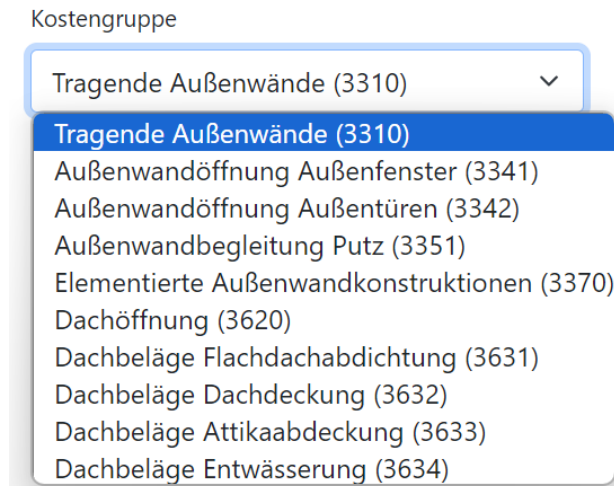


Abbildung 95: Dropdown Kostengruppen (Prototyp) (Quelle: eigene Darstellung)

Die Werte werden an dieser Stelle one-hot-kodiert übergeben, das heißt, dass für 3310 der Wert "1,0,0,0,0,0,0,0,0,0" übergeben wird, für 3341 "0,1,0,0,0,0,0,0,0,0" usw. – der vollständige Code befindet sich im Anhang D 6.

Im nächsten Schritt werden das Baujahr (bzw. Einbaujahr des Bauteiles) und das Alter des Bauteiles durch den Nutzer in die Input-Felder eingetragen (vgl. Abbildung 96).




Abbildung 96: Inputs Alter und Baujahr (Prototyp) (Quelle: eigene Darstellung)

Sofern kein Alter angegeben ist, wird die Zerfallsrate des Bauteils für den Zeitraum zwischen dem Baujahr und dem aktuellen Jahr bestimmt. Bei Angabe eines Alters wird die Lebensdauerprognose für den Zeitpunkt ermittelt, zu dem das Bauteil das angegebene Alter erreicht hat.

Ausgehend von den Werten in der Abbildung 96 wäre dies das Jahr 1990.

Diese Funktion wurde in die Anwendung integriert, um die Möglichkeit zu gewährleisten, Prognosen für Zeiträume vor und nach dem aktuellen Jahr zu erstellen und damit den Verlauf der Abnutzungskurve zu erfassen.

Es ist zu beachten, dass das Modell ausschließlich mit Inspektionsdaten der Jahre 2019, 2020, 2021 und 2022 trainiert wurde. Eine Vorhersage des neuronalen Modells für das Jahr 1990

könnte die Fähigkeiten des Modells übersteigen, eine zuverlässige Vorhersage für einen Zustand zu liefern, der 30 Jahre in der Vergangenheit liegt.

Im Prototyp wurden keine Einschränkungen für die Benutzereingabe (Validierung) eingeführt. Dies bedeutet, dass der Benutzer die Eingabefelder nach eigenem Ermessen ausfüllen kann.

Je nach Art der Prognose hat der Benutzer die Möglichkeit, die externen Umwelteinflüsse manuell einzugeben, wie in der Abbildung 97 dargestellt ist, oder den Standort durch Eingabe einer Postleitzahl zu bestimmen (vgl. Abbildung 98).

| Lufttemperatur | Niederschlag | Sonnenscheindauer | Windlastzone | Schneelastzone | Hagelzone | Erschütterung |
|----------------|--------------|-------------------|--------------|----------------|-----------|---------------|
| 10,5 | 633,3 | 1575 | 2 | 1 | 7,5 | 1,6 |

Abbildung 97: Prognose über Einflussfaktoren: Eingabe der äußeren Umwelteinflüsse (Prototyp)
(Quelle: eigene Darstellung)

PLZ

Abbildung 98: Prognose über Standort: Eingabe der Postleitzahl (Prototyp) (Quelle: eigene Darstellung)

Bei der Prognose über den Standort werden in einem Zwischenschritt in PHP die relevanten Umwelteinflüsse anhand der Postleitzahl aus einer MySQL-Datenbank ermittelt. Die Struktur der Tabelle „Umwelteinflüsse“ befindet sich im Anhang D 7.

Im nächsten Schritt werden die Werte für den Scaler aus der JSON-Datei geladen und dekodiert.

Im nächsten Schritt wird die JSON-Datei mit den Scaler-Parametern eingelesen und die Scaler-Parameter werden extrahiert und decodiert. Die ermittelten Umwelteinflüsse werden mit allen anderen Daten (Kostengruppe, Alter, Baujahr) zu einem Array zusammengeführt.

Dieses Array wird dann in zwei getrennte Arrays aufgeteilt: eines für kategoriale Features und eines für metrische Features.

Die Werte des metrischen Arrays werden mit Hilfe des Skalierers transformiert. Anschließend werden alle Features, die kategorialen Features und die skalierten metrischen Features, wieder zu einem Array zusammengeführt.

Diese aggregierten Daten werden an das versteckte HTML-Input-Element mit der ID 'merged_array' übergeben. Mit der Hilfe dieses Inputs wird das Array im nächsten Schritt per JavaScript an das neuronale Modell übergeben.

Das neuronale Modell, welches im JSON-Format als TensorFlow-Modell vorliegt, wird mittels JavaScript und der JavaScript-TensorFlow-Bibliothek geladen. Die Prognosedaten des Modells werden anschließend per JavaScript an ein HTML-Input-Element übergeben, das zur

Darstellung der Daten Zerfallsrate verwendet wird. Weitere Informationen in Form von vollständig kommentiertem Code sind im Anhang D 9 verfügbar.

Der abschließende Schritt der Lebensdauerprognose ist die Berechnung der prozentualen Restlebensdauer mittels JavaScript. Die Berechnung erfolgt für den Zeitpunkt, zu dem das Bauteil das angegebene Alter erreicht hat. Wurde kein Alter angegeben, erfolgt die Berechnung für das aktuelle Jahr.

Zur Darstellung der prozentualen Restlebensdauer wird das Ergebnis von 100 subtrahiert. Die Berechnung ergibt sich aus der Umstellung der Formel der Zerfallsrate (vgl. Formel 9.3).

Die prozentuale Restlebensdauer nach DIN 31051 [4] wird mittels JavaScript an einen weiteren HTML-Input übergeben und dort dargestellt. Eine visuelle Darstellung dieser Oberfläche findet sich in der Abbildung 99.

| | |
|------------------|--------------------|
| Zerfallsrate | 0,8806787133216858 |
| Abnutzungsvorrat | 25,38 |

Abbildung 99: Darstellung der Zerfallsrate und des Abnutzungsvorrates (Prototyp) (Quelle: eigene Darstellung)

10 Evaluation der Ergebnisse

10.1 Einleitung

In diesem Kapitel werden die Prognosen des neuronalen Modells erörtert und evaluiert, welches in Kapitel 9.3 entwickelt wurde. Hierbei wird der Prototyp verwendet, der in Kapitel 9.4 erstellt wurde.

Vor der Evaluation der Ergebnisse ist eine kritische Betrachtung des verwendeten Datensatzes erforderlich, um festzustellen, ob er repräsentativ ist und somit die Aussagekraft der Prognosen unterstützt.

10.2 Kritische Betrachtung

Hinsichtlich der Anzahl der Daten-Zeilen in dem verwendeten Datensatz (1652 Zeilen ohne synthetische Daten, 2560 Zeilen inklusive synthetischer Daten) bewegt sich der Datensatz im unteren Bereich vergleichbarer Datensätze [177–180]. Ein bekannter Datensatz im Immobilienbereich mit einem Regressionsproblem ist beispielsweise der sogenannte „California Housing“-Datensatz [180], in dem der Medianwert von Häusern in kalifornischen Bezirken anhand von acht Features ermittelt wird. Die 20.460 Datensätze dieses Datensatzes wurden aus der amerikanischen Volkszählung von 1990 abgeleitet. Die Features, die mit dem Medianwert der Häuser gelabelt sind, sind z.B. der Medianwert des Alters der Häuser im gleichen Block oder der Längen- und Breitengrad des Blocks, in dem das Haus steht [180, 181]. Dieser Datensatz ist Bestandteil der von Scikit-learn standardmäßig bereitgestellten Datensätze [182]. Der wohl bekannteste Datensatz zur Regression im Immobilienbereich ist jedoch der „Boston Housing“-Datensatz von Harrison und Rubinfeld [183] aus dem Jahr 1978, der ebenfalls eine amerikanische Volkszählung als Datenquelle hat. In diesem Datensatz wird über vierzehn Features der Medianwert von Häusern in Boston ermittelt [184, 185]. In vielen Publikationen [186–188] in dem Bereich des maschinellen Lernens wird auf diesen Datensatz als Benchmark-Datensatz zurückgegriffen [189].

Als soziologisch sehr problematisch wird heute dabei angesehen, dass Harrison und Rubinfeld das Ziel verfolgten, den Zusammenhang zwischen einem der Features, der Stickoxidkonzentration, und dem Medianwert der Häuser zu analysieren und daraus Rückschlüsse auf die Zahlungsbereitschaft für eine bessere Luftqualität zu ziehen [189]. Aus diesem Grund wurde der Datensatz in den letzten Jahren aus vielen Bibliotheken, wie beispielsweise der Scikit-learn-Bibliothek, entfernt [190]. Heute wird der „Boston Housing“-Datensatz als Beispiel für systemischen Rassismus in Daten genannt [189], in der Scikit-learn-Bibliothek wird auf der Webseite an der Stelle des „Boston Housing“-Datensatz auf den „California Housing“-Datensatz verwiesen [190]. So heißt es wörtlich auf der Webseite „The Boston housing prices dataset has an ethical problem. You can refer to the documentation of this function for further detail. The scikit-learn maintainers therefore strongly discourage the use of this dataset unless the purpose of the code is to study and educate about ethical issues in data science and machine learning.“ [190].

Die Relevanz dieses Sachverhalts für die Arbeit ergibt sich daraus, dass der „Boston Housing“-Datensatz lediglich 506 Zeilen [184] enthält, was bedeutend kleiner ist als der in dieser Arbeit verwendete Datensatz. Daraus lässt sich schließen, dass die geringe Anzahl der Zeilen (2560) im verwendeten Datensatz kein Indikator für eine fehlende Repräsentativität des Datensatzes ist.

Weiter kritisch anzumerken gilt, dass die Betrachtung von lediglich vier Standorten möglicherweise zu gering ist. Durch die kleinen Wertebereiche der Trainingsdaten (vgl. Tabelle 16, Tabelle 17 und Tabelle 18) und unter der Annahme, dass der Verlauf der Kurve des Abnutzungsvorrates und die zugehörigen Abhängigkeiten nicht linear sind, besteht die Möglichkeit, dass die Vorhersagen des neuronalen Modells bei Eingaben, die weit außerhalb des Trainingsbereichs liegen, zu falschen Ergebnissen führen. Grundsätzlich ist ein neuronales Modell in der Lage, realistische Vorhersagen für Werte zu generieren, die außerhalb des trainierten Wertebereichs liegen. Die Genauigkeit dieser Vorhersagen hängt von der Qualität und Quantität der für das Training verwendeten Daten ab.

Um solche Fehler ausschließen zu können, wird der Wertebereich für die Eingaben auf der Grundlage der Wertebereiche der Trainingsdaten (vgl. Tabelle 16, Tabelle 17 und Tabelle 18) folgendermaßen beschränkt (vgl. Tabelle 37):

Tabelle 37: Wertebereiche und Mittelwerte der Trainingsdaten (Quelle: eigene Darstellung)

| Parameter | Bezeichnung | Bereich | Mittelwert |
|-----------|---------------------------------|---|---------------------------|
| P1 | Lufttemperatur ⁸¹ | 10,5 C° bis 10,9 C° | 10,7 C° |
| P2 | Niederschlag ⁸² | 585 mm bis 711,9 mm | 648,45 mm |
| P3 | Sonnenscheindauer ⁸³ | 1575 h bis 1734,2 h | 1.654,6 h |
| P4 | Windlastzone ⁸⁴ | 1 bis 2 | 1,5 |
| P5 | Schneelastzone ⁸⁵ | 1 bis 2 | 1,5 |
| P6 | Erschütterung ⁸⁶ | $\leq 0,3 \text{ m/s}^2$ bis $\leq 1,6 \text{ m/s}^2$ | $\leq 0,95 \text{ m/s}^2$ |
| P7 | Hagelzone ⁸⁷ | 7,5 bis 15 | 11,25 |
| P8 | Frosttage ⁸⁸ | 51,8 bis 63,8 | 57,8 |

Dabei ist zusätzlich zu anzumerken, dass die Erfassung von Zuständen auf der Basis von Zustandsklassifikationen mit Varianzen behaftet sein kann, die zu einem Verlust an Prognosequalität führen können.

⁸¹ Vieljährige Mittelwerte 1991 – 2020.

⁸² Vieljährige Mittelwerte 1991 – 2020.

⁸³ Vieljährige Mittelwerte 1991 – 2020.

⁸⁴ Nach der DIN EN 1991-1-4/NA:2010-12.

⁸⁵ Nach der DIN EN 1991-1-3/NA.

⁸⁶ Mittelwert der Amplitude im Plateaubereich des Antwortspektrums $S_{ap,R}$.

⁸⁷ Nach den Hagelzonen der Münchener Rück (vgl. Abbildung 58).

⁸⁸ Vieljährige Mittelwerte 1991 – 2020.

10.3 Auswertung

10.3.1 Einleitung

Eine umfassende multivariate Analyse, die alle 256 möglichen Kombinationen pro Bauteil berücksichtigt, würde den Rahmen dieser Arbeit erheblich überschreiten. Dennoch werden im Verlauf dieses Kapitels die repräsentativsten Auswirkungen auf die einzelnen Bauteile herausgegriffen, um eine detailliertere Darstellung zu ermöglichen.

An dieser Stelle ist anzumerken, dass die Datenanalyse zeigt, dass Bauteile neueren Datums im Allgemeinen eine etwas längere Lebensdauer aufweisen als ihre älteren Gegenstücke.

Dieses Phänomen wird beispielhaft in der Abbildung 100 an der tragenden Außenwand für die Baujahre 1973, 1985 und 2000 dargestellt.




Abbildung 100: Verlauf der Kurve des Abnutzungsvorrates einer tragenden Außenwand (Baujahr 1973, 1985, 2000)⁸⁹ (Quelle: eigene Darstellung)

Die Auswertung erfolgt nach Bauteilen gruppiert, wobei für jedes Bauteil verschiedene Szenarien dargestellt werden.

In diesen Szenarien wird der verbleibende Abnutzungsvorrat für jede Altersklasse berechnet und grafisch in Form von Kurven dargestellt. Für die spezifische Komponente wurde der verbleibende Abnutzungsvorrat nicht für jedes Jahresintervall, sondern nur für diskrete Intervalle von drei oder fünf Jahren ermittelt.

Auf eine Interpretation der Kurven wird verzichtet, da die Auswirkungen der Einflüsse auf den Verlauf der Abnahme des Abnutzungsvorrats für den Betrachter aus den dargestellten Diagrammen klar ersichtlich sind.

Für die Visualisierung der Diagramme wird auf die Open Source JavaScript Bibliothek Chart.js (chartjs.org) zurückgegriffen.

Die Diagramme befinden sich in den jeweiligen Unterkapiteln der Bauteile (Kapitel 0 bis Kapitel 10.3.11).

⁸⁹ Bei den restlichen Einflussfaktoren wurden die standortabhängigen vieljährigen Mittelwerte des Standorts 3 verwendet (vgl. Tabelle 17, Tabelle 18, Tabelle 19).

Bei den ersten Szenarien soll die positive bivariate Beziehung zwischen einem einzelnen Parameter und der Zerfallsrate bzw. der Lebensdauern betrachtet werden. Dabei wird ein Parameter auf den höchsten Wert des zugrundeliegenden Wertebereichs gesetzt (vgl. Tabelle 37), während die übrigen Parameter mit ihren jeweiligen Mittelwerten belegt werden.

Als Anhaltspunkt soll die graue, gestrichelte Linie dienen, welche sich aus den Mittelwerten aller Parameter ergibt.

Anmerkung: Die in den Diagrammen dargestellten Lebensdauern sind aufgrund der Verwendung von Mittelwerten nicht unbedingt repräsentativ, da die verwendeten Kombinationen unrealistisch sind. Diese Darstellungen sollen lediglich die Auswirkungen verschiedener Parameter veranschaulichen. Daher sollte das Hauptaugenmerk auf der Analyse des Verhältnisses der Abweichungen und nicht auf der Interpretation der absoluten Lebensdauern liegen. Für repräsentative Lebensdauern wird auf die Vergleiche der standortspezifischen Lebensdauern in Kapitel 11 verwiesen.

In Abbildung 40 sind die positiven bivariate Szenarien entsprechend dargestellt. Die Bezeichnungen der Parameter befinden sich in der Tabelle 37.

Das \bar{x} steht für den Mittelwert eines Parameters, ein + für den Maximalwert des Bereiches, ein – für den Minimalwert des Bereiches (vgl. Tabelle 37).

Tabelle 38: positive bivariate Szenarien (a-Szenarien) (Quelle: eigene Darstellung)

| Bivariate Szenarien (a1 – a8) | P1 | P2 | P3 | P4 | P5 | P6 | P7 | P8 |
|-----------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| a0 „Mittelwerte“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| a1 „erhöhte Lufttemperatur“ | + | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| a2 „erhöhter Niederschlag“ | \bar{x} | + | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| a3 „erhöhte Sonnenscheindauer“ | \bar{x} | \bar{x} | + | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| a4 „erhöhte Windlastzone“ | \bar{x} | \bar{x} | \bar{x} | + | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| a5 „erhöhte Schneelastzone“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | + | \bar{x} | \bar{x} | \bar{x} |
| a6 „erhöhte Erdbebenzone“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | + | \bar{x} | \bar{x} |
| a7 „erhöhte Hagelzone“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | + | \bar{x} |
| a8 „erhöhte Anzahl an Frosttagen“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | + |

Im Gegensatz dazu werden in den b-Szenarien die Auswirkungen betrachtet, wenn der entsprechende Parameter nicht erhöht, sondern verringert wird. Die einzelnen Szenarien sind in der Tabelle 39 dargestellt.

Tabelle 39: negative bivariate Szenarien (b-Szenarien) (Quelle: eigene Darstellung)

| Bivariate Szenarien (b1 – b8) | P1 | P2 | P3 | P4 | P5 | P6 | P7 | P8 |
|---------------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| b0 „Mittelwerte“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| b1 „verminderte Lufttemperatur“ | - | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| b2 „verminderte Niederschlag“ | \bar{x} | - | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| b3 „verminderte Sonnenscheindauer“ | \bar{x} | \bar{x} | - | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| b4 „verminderte Windlastzone“ | \bar{x} | \bar{x} | \bar{x} | - | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| b5 „verminderte Schneelastzone“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | - | \bar{x} | \bar{x} | \bar{x} |
| b6 „verminderte Erdbebenzone“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | - | \bar{x} | \bar{x} |
| b7 „verminderte Hagelzone“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | - | \bar{x} |
| b8 „verminderte Anzahl an Frosttagen“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | - |

Um die Auswirkungen multivariater Parameterkombinationen auf die Lebensdauer zu veranschaulichen, werden im Folgenden ausgewählte spezifische Szenarien vorgestellt.

Dabei beschränke ich mich auf eine begrenzte Anzahl von Szenarien, da eine vollständige Darstellung aller denkbaren Kombinationen, wie bereits erwähnt, den Rahmen dieser Arbeit überschreiten würde.

Folgende Szenarien wurden für diese Arbeit konzipiert:

I. Szenario (C1): Kalt und feucht:

- „verminderte Lufttemperatur“,
- „erhöhter Niederschlag“,
- „erhöhte Schneelastzone“,
- „erhöhte Anzahl an Frosttagen“.

II. Szenario (C2): Warm und trocken:

- „erhöhte Lufttemperatur“,
- „verminderter Niederschlag“.

III. Szenario (C3): Warm und feucht:

- „erhöhte Lufttemperatur“,
- „erhöhter Niederschlag“,
- „verminderte Schneelastzone“,
- „verminderte Anzahl an Frosttagen“.

IV. Szenario (C4): Kalt und trocken:

- „verminderte Lufttemperatur“,
- „verminderter Niederschlag“,

- „erhöhte Schneelastzone“,
- „erhöhte Anzahl an Frosttagen“.

V. Szenario (C5): Warm, feucht und viel Wind:

- „erhöhte Lufttemperatur“,
- „erhöhter Niederschlag“,
- „erhöhte Windlastzone“.
- „verminderte Schneelastzone“,
- „verminderte Anzahl an Frosttagen“.

VI. Szenario (C6): Warm, feucht und wenig Wind:

- „erhöhte Lufttemperatur“,
- „erhöhter Niederschlag“,
- „verminderte Windlastzone“.
- „verminderte Schneelastzone“,
- „verminderte Anzahl an Frosttagen“.

VII. Szenario (C7): Kalt, trocken und wenig Wind:

- „verminderte Lufttemperatur“,
- „verminderter Niederschlag“,
- „verminderte Windlastzone“,
- „erhöhte Schneelastzone“,
- „erhöhte Anzahl an Frosttagen“.

Die Tabelle 40 zeigt die einzelnen Szenarien mit den jeweiligen Parametern im Überblick.

Tabelle 40: multivariate Szenarien (c-Szenarien) (Quelle: eigene Darstellung)

| Multivariate Szenarien (c1 – c8) | P1 | P2 | P3 | P4 | P5 | P6 | P7 | P8 |
|-----------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| c0 „Mittelwerte“ | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} |
| c1 „kalt und feucht“ | - | + | \bar{x} | \bar{x} | + | \bar{x} | \bar{x} | + |
| c2 „warm und trocken“ | + | - | \bar{x} | \bar{x} | \bar{x} | \bar{x} | \bar{x} | - |
| c3 „warm und feucht“ | + | + | \bar{x} | \bar{x} | - | \bar{x} | \bar{x} | - |
| c4 „kalt und trocken“ | - | - | \bar{x} | \bar{x} | + | \bar{x} | \bar{x} | + |
| c5 „warm, feucht und viel Wind“ | + | + | \bar{x} | + | - | \bar{x} | \bar{x} | - |
| c6 „warm, feucht und wenig Wind“ | + | + | \bar{x} | - | - | \bar{x} | \bar{x} | - |
| c7 „kalt, trocken und wenig Wind“ | - | - | \bar{x} | - | + | \bar{x} | \bar{x} | + |

In den Unterkapiteln 10.3.2 bis 10.3.11 befindet sich die grafische Auswertung.

10.3.2 Tragende Außenwände (3310)




Abbildung 101: a-Szenario für die KG 3310 (Quelle: eigene Darstellung)




Abbildung 102: b-Szenario für die KG 3310 (Quelle: eigene Darstellung)




Abbildung 103: c-Szenario für die KG 3310 (Quelle: eigene Darstellung)

10.3.3 Außenfenster (3341)




Abbildung 104: a-Szenario für die KG 3341 (Quelle: eigene Darstellung)




Abbildung 105: b-Szenario für die KG 3341 (Quelle: eigene Darstellung)




Abbildung 106: c-Szenario für die KG 3341 (Quelle: eigene Darstellung)

10.3.4 Außentüren (3342)




Abbildung 107: a-Szenario für die KG 3342 (Quelle: eigene Darstellung)




Abbildung 108: b-Szenario für die KG 3342 (Quelle: eigene Darstellung)




Abbildung 109: c-Szenario für die KG 3342 (Quelle: eigene Darstellung)

10.3.5 Außenwandbekleidung Putz (3351)




Abbildung 110: a-Szenario für die KG 3351 (Quelle: eigene Darstellung)




Abbildung 111: b-Szenario für die KG 3351 (Quelle: eigene Darstellung)




Abbildung 112: c-Szenario für die KG 3351 (Quelle: eigene Darstellung)

10.3.6 Elementierte Außenwandkonstruktionen (3370)

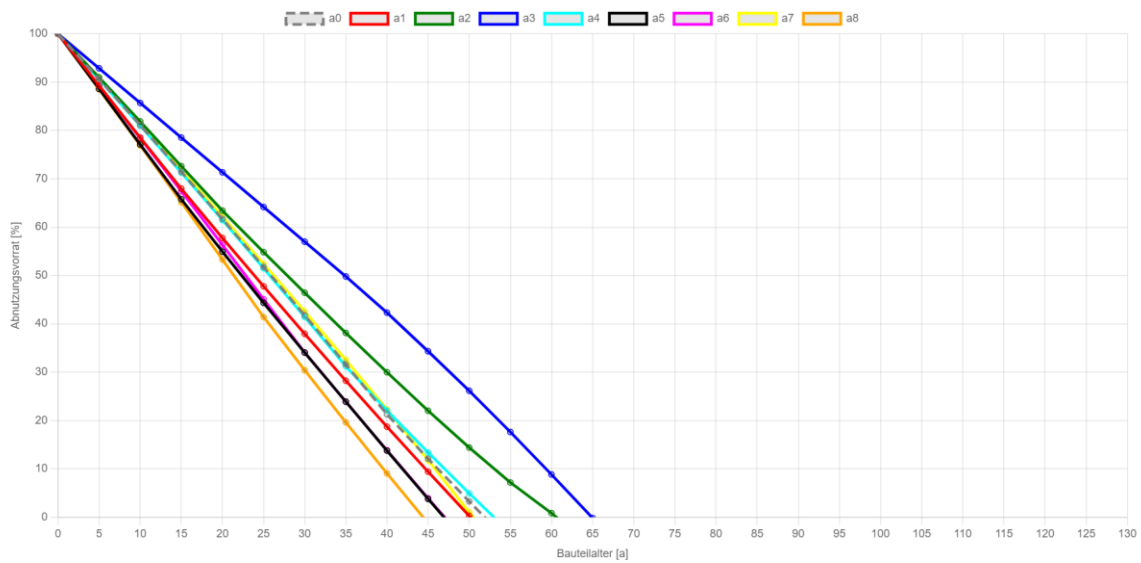


Abbildung 113: a-Szenario für die KG 3370 (Quelle: eigene Darstellung)




Abbildung 114: b-Szenario für die KG 3370 (Quelle: eigene Darstellung)




Abbildung 115: c-Szenario für die KG 3370 (Quelle: eigene Darstellung)

10.3.7 Dachöffnungen (3620)




Abbildung 116: a-Szenario für die KG 3620 (Quelle: eigene Darstellung)




Abbildung 117: b-Szenario für die KG 3620 (Quelle: eigene Darstellung)




Abbildung 118: c-Szenario für die KG 3620 (Quelle: eigene Darstellung)

10.3.8 Flachdachabdichtung (3631)




Abbildung 119: a-Szenario für die KG 3631 (Quelle: eigene Darstellung)




Abbildung 120: b-Szenario für die KG 3631 (Quelle: eigene Darstellung)




Abbildung 121: c-Szenario für die KG 3631 (Quelle: eigene Darstellung)

10.3.9 Dachdeckung (3632)




Abbildung 122: a-Szenario für die KG 3632 (Quelle: eigene Darstellung)




Abbildung 123: b-Szenario für die KG 3632 (Quelle: eigene Darstellung)




Abbildung 124: c-Szenario für die KG 3632 (Quelle: eigene Darstellung)

10.3.10 Attikaabdeckung (3633)




Abbildung 125: a-Szenario für die KG 3633 (Quelle: eigene Darstellung)




Abbildung 126: b-Szenario für die KG 3633 (Quelle: eigene Darstellung)




Abbildung 127: c-Szenario für die KG 3633 (Quelle: eigene Darstellung)

10.3.11 Entwässerung (3634)




Abbildung 128: a-Szenario für die KG 3634 (Quelle: eigene Darstellung)




Abbildung 129: b-Szenario für die KG 3634 (Quelle: eigene Darstellung)




Abbildung 130: c-Szenario für die KG 3634 (Quelle: eigene Darstellung)

11 Zusammenfassung und Fazit

Beim Vergleich der standortspezifischen Prognosen des neuronalen Modells für Betonaußenwände (vgl. Abbildung 131) mit den standortunabhängigen Richtwerten des BTE-Arbeitskreises aus dem Jahr 2019 (vgl. Anhang A 11) zeigt sich, dass der Mittelwert von 90 Jahren für die Lebensdauern von Betonaußenwänden grundsätzlich als durchschnittlich repräsentativ angesehen werden kann. Der ermittelte Mittelwert der Prognosen des neuronalen Modells für die Lebensdauer von Betonaußenwänden beträgt etwa 92 Jahre. Dieser Wert liegt nahe am Mittelwert der Richtwerte des BTE-Arbeitskreises, der bei 90 Jahren liegt (vgl. Abbildung 131).

Gleichzeitig wird aber auch deutlich, dass die tatsächlichen Lebensdauern in Abhängigkeit von den spezifischen Standortbedingungen erheblich von diesem Mittelwert abweichen können.




Abbildung 131: Standortspezifischer Verlauf des Abbaus des Abnutzungsvorrates der tragenden Außenwände (Betonfertigbauteile/Ortbeton) für die vier Standorte (Quelle: eigene Darstellung)

Aufgrund der äußeren Umwelteinflüsse ist am Standort 4 und am Standort 2 mit einer Lebensdauer der Betonaußenwände von unter achtzig Jahren zu rechnen, also deutlich kürzer als die vom BTE-Arbeitskreis angenommenen neunzig Jahre.

Die erwartete Lebensdauer am Standort 2 liegt dagegen deutlich über diesen 90 Jahren. Die standortbedingte Lebensdauerdifferenz bei Betonaußenwände beträgt für dieses Beispiel ca. vierzig Jahre.

Für andere Bauteile wie Außentüren (Vollholz) liegen die standortabhängigen Prognosen (vgl. Abbildung 132) deutlich über den vom BTE-Arbeitskreis empfohlenen 40 Jahren (Mittelwert).

Im Vergleich hierzu: Nach Ritter liegen technische Referenzlebensdauern für Außentüren aus Holz bei 41 Jahren [7].




Abbildung 132: Standortspezifischer Verlauf des Abbaus des Abnutzungsvorrates der Außentüren (Holz) für die vier Standorte (Quelle: eigene Darstellung)

Bei Außentüren aus dem Material Vollholz beträgt die standortbedingte Lebensdauerdifferenz ca. elf Jahre.

Insgesamt kann festgestellt werden, dass das Ziel dieser Arbeit, eine alternative AI-gestützte Methode zur Bestimmung standortspezifischer Lebensdauern von Bauteilen mit Hilfe eines neuronalen Modells zu entwickeln, erfolgreich erreicht wurde. Dabei wird nicht nur festgestellt, dass Referenzlebensdauern aus der Literatur nicht immer anwendbar sind, sondern, dass Lebensdauern stark von Einflussfaktoren abhängig sind. Gerade die äußeren Umwelteinflüsse spielen dabei bezüglich der äußeren Gebäudehülle eine große Rolle.

Die Faktorenmethode nach ISO 15686 ist derzeit (Stand 01/2023) noch alternativlos und wird vom Bundesamt für Bauwesen und Raumordnung unter Berücksichtigung des Forschungsberichtes „*Lebens- und Nutzungsdauer von Bauteilen*“ [11] von Bahr und Lennerts für die Ermittlung von Lebensdauern empfohlen [14]. Neben [14] gibt es viele weitere wissenschaftliche Arbeiten, wie beispielsweise die Dissertation „*Lebensdauer von Bauteilen und Bauelementen*“ von Ritter [7], in denen versucht wird, die Problematiken der Faktorenmethode zu adressieren. Denn ohne die richtigen Faktoren und geeigneten Referenzlebensdauern ist die Berechnung genauer Lebensdauern mit der Faktorenmethode kaum möglich.

Die vorliegende Arbeit zeigt, dass es neben der Weiterentwicklung des Ansatzes der ISO 15686 (Faktorenmethode) auch alternative Methoden wie neuronale Modelle zur Bestimmung der Lebensdauern von Bauteilen gibt.

Obwohl die Prognosegenauigkeit prozentual bei über 90 % liegt (vgl. Kapitel 9.3.4), muss hinsichtlich der Ergebnisse kritisch angemerkt werden, dass die verwendeten Inspektionsdaten aufgrund der subjektiven menschlichen Wahrnehmung einer gewissen Verzerrung unterliegen. Darüber hinaus ergeben sich zusätzliche Unschärfen durch die Zustandsklassifizierung der Bauteile (A bis E) und die darauf basierende Ermittlung des Abnutzungsvorrats. In der Phase der Datenaufbereitung wurde versucht, Unschärfen möglichst zu minimieren. Trotzdem können diese Faktoren die Qualität der verfügbaren Trainingsdaten beeinträchtigen und somit die Genauigkeit der Vorhersagen des Modells beeinflussen.

Um die prognostizierte Lebensdauer methodisch zu evaluieren, wird am Beispiel der tragenden Außenwand (vgl. Kapitel 10.3.2) aus Betonfertigteile bzw. Ortbeton eine Gegenüberstellung mit den in anderen relevanten Werken beschriebenen Lebensdauern durchgeführt. Durch diese Gegenüberstellung lässt sich die prognostizierte Lebensdauer im Vergleich zu etablierten Referenzlebensdauern in einen Kontext setzen.

Das Bundesinstitut für Bau-, Stadt- und Raumforschung gibt in seiner aktuellen Veröffentlichung der „Nutzdauer von Bauteilen“ [191] vom 24.02.2017 die Lebensdauer von Betonwänden von ≥ 50 Jahren an (vgl. *BBSR 2017* in der Abbildung 133).

Eine Lebensdauer von 73 bis 120 Jahren ergibt die statistische Auswertung der BTE-Umfrage im Arbeitsblatt der BTE-Arbeitsgruppe [8] von 2008 (vgl. *Umfrage BTE 2008* in der Abbildung 133).




Abbildung 133: Vergleich der prognostizierten Lebensdauer für Außenwände (Beton) mit Referenzlebensdauer aus der Literatur (Quelle: eigene Darstellung)

In der aktuellen Ausgabe der Arbeitsgruppe „Lebensdauer von Bauteilen“ [12] der BTE von 2019 wird ein Mittelwert von 90 Jahren für bekleidete Außenwände aus Beton angegeben (vgl. *MW BTE-AG 2019* in der Abbildung 133).

Weitere Veröffentlichungen wie das Info-Blatt Nr. 4.2 „Lebensdauer von Bauteilen und Bauschichten“ [192] (2009) des Kompetenzzentrums „Kostengünstig qualitätsbewusst Bauen“ im Institut für Erhaltung und Modernisierung von Bauwerken e.V. (IEMB) an der TU Berlin geben eine mittlere Lebenserwartung von 120 Jahren an (vgl. *MW IEMB 2009* in der Abbildung 133), bei einer Spanne von minimal hundert Jahren und maximal hundertfünfzig Jahren [192].

Arlt und Pfeifer [2] geben in ihrem Forschungsbericht (F 815 [2]) von Juni 2004 auf der Grundlage einer Befragung von Wohnungsunternehmen, eine Lebensdauer von 80 Jahren an (vgl. *MW IFB 2004* in der Abbildung 133).

Bei kritischer Betrachtung stellt sich zudem die Frage, ob ein künstliches neuronales Netz die einzige Methode ist, um dieses multiple nichtlineare Regressionsproblem zu lösen. Einer der wohl am weitesten verbreiteten alternativen Ansätze ist die Lineare Regression (kurz: LinReg).

Die Lineare Regression, welche sich durch die lineare Funktion definiert, ist ähnliche wie ein Neuron aufgebaut (vgl. 11.1).

$$\hat{y} = a + b * x \quad 11.1$$

Für die multiple lineare Regression sieht die Formel folgendermaßen aus (vgl. 11.2).

$$\hat{y} = b_1 * x_1 + b_2 * x_2 + \dots + b_n * x_n + a \quad 11.2$$

Wie bei künstlichen neuronalen Netzen gibt es Inputs bzw. Features mit Gewichten und einem Bias-Wert. Es handelt sich um ein einschichtiges Netz mit nur einem Neuron. Der entscheidende Unterschied zwischen einem mehrschichtigen künstlichen neuronalen Netz und einer multiplen linearen Regression besteht darin, dass die multiple lineare Regression nicht in der Lage ist, nicht-lineare Beziehungen zwischen den Features und der Zielvariable abzubilden. Das künstliche neuronale Netz hingegen kann nichtlineare Muster erfassen und abbilden.

Außerdem setzt die multiple lineare Regression voraus, dass ausschließlich die relevanten Features übergeben werden, das künstliche neuronale Netz bewertet die Relevanz der übergebenen Features eigenständig.

Ausgehend von den gegebenen Randbedingungen der linearen Regression und unter Berücksichtigung der Charakteristika des vorliegenden Datensatzes, bei dem bereits im Vorfeld viele nichtlineare Abhängigkeiten vermutet wurden, ist die Anwendung der linearen Regression als statistisches Modell zur Analyse der Daten nicht geeignet.

12 Ausblick

Vor dem Hintergrund sich ändernder Umweltbedingungen, insbesondere im Hinblick auf den fortschreitenden Klimawandel, wird deutlich, dass äußere Umwelteinflüsse zukünftig eine immer größere Rolle bei der Bestimmung der Lebensdauer von Bauteilen und den daraus resultierenden Instandsetzungskosten spielen werden.

Am Beispiel der Gebäudeaußenhülle wurde erfolgreich demonstriert, dass methodische Alternativen zur Faktorenanalyse existieren und dass die Lebensdauerprognosen mit neuronalen Modellen verwertbare Ergebnisse liefern und Problemstellungen der Faktorenanalyse lösen können.

Angesichts der sich verändernden Einflüsse, wie beispielsweise des zunehmenden Jahresmittels der Lufttemperatur in Deutschland (vgl. Abbildung 134), muss geprüft werden, ob alternative Baustoffe resilienter gegenüber den in Deutschland zukünftig vorherrschenden Bedingungen sind.




Abbildung 134: Abweichung des Jahresmittels der Lufttemperatur für Deutschland vom vieljährigen Mittel 1961-1990 für den Zeitraum 1881-2021 (Quelle: [193])

Für das Training eines neuronalen Modells für alle Bauelemente und weitere Baustoffe wäre jedoch ein großer und diversifizierter Datensatz erforderlich. Der in dieser Arbeit verwendete Datensatz war ausreichend, um die Funktionalität an einer beschränkten Menge an Bauteilen zu demonstrieren. Er ist jedoch aufgrund seiner geringen Diversifikation nur begrenzt einsetzbar. Ein Datensatz mit mehr Standorten würde die Vorhersagequalität für weitere Standorte, die außerhalb der Wertebereiche des Trainings liegen, erheblich verbessern.

Idealerweise sollten Inspektionsdaten von Gebäuden gesammelt werden, die gleichmäßig über Deutschland verteilt sind, um möglichst viele Kombinationen von äußeren Umwelteinflüssen abzudecken. In diesem Zusammenhang sollte jedoch berücksichtigt werden, dass

beispielsweise in Norddeutschland teilweise andere Baustile und Baustoffe zum Einsatz kommen als im südlichen Teil Deutschlands. In den nördlichen Teilen Deutschlands, insbesondere in Regionen wie Ostfriesland und Nordfriesland, findet man häufig das charakteristische Friesenhaus. Dieser Baustil zeichnet sich durch eine markante Architektur aus. Das Dach ist mit Reet (Schilfrohr) gedeckt und das Mauerwerk besteht aus roten Ziegelsteinen. Im Gegensatz dazu prägt der alpenländische Baustil die südlichen Regionen Deutschlands, insbesondere in Bayern. Hier findet man vermehrt Gebäude, bei denen die Fassade ausschließlich aus Holz besteht. Diese Bauweise spiegelt die traditionelle Architektur der Alpenregion wider und ist eng mit der ländlichen Lebensweise verbunden.

Um sicherzustellen, dass das Modell auf die gängigen Materialien in verschiedenen Baustilen anwendbar ist, ist eine umfangreiche Datenerhebung an verschiedenen Standorten und Gebäuden unerlässlich, die eine Vielzahl von Baustoffen verwenden.

Entscheidend für die Qualität dieser Daten ist eine standardisierte und objektive Bewertung der Bauteile bei der Inspektion der Gebäude. Die Integration dieser Daten in das neuronale Modell könnte eine genauere Vorhersage der Lebensdauer von Bauteilen in verschiedenen Regionen Deutschlands ermöglichen. Dadurch könnten für alle Gebäude genauere Empfehlungen für Instandhaltungsmaßnahmen generiert werden, was langfristig zu einer effizienteren Ressourcennutzung und einer längeren Lebensdauer von Gebäuden beitragen könnte. Bereits in der Planungsphase von Bauprojekten können die Auswirkungen sich ändernder Umweltbedingungen, insbesondere vor dem Hintergrund des Klimawandels, berücksichtigt werden. Eine gezielte Auswahl von Baustoffen kann dazu beitragen, die Resilienz eines Gebäudes gegenüber zukünftig veränderten Umweltbedingungen zu erhöhen. Dabei sollten Baustoffe bevorzugt werden, die sich gegenüber den prognostizierten Umweltbelastungen als besonders robust erweisen und somit den Herausforderungen eines sich ändernden Klimas besser gewachsen sind.

Die frühzeitige Berücksichtigung von Umweltaspekten im Planungsprozess durch die gezielte Auswahl von Baustoffen, deren Lebensdauer möglichst widerstandsfähig gegenüber den prognostizierten zukünftigen Umweltbedingungen ist, ermöglicht es, gezielt auf die Herausforderungen des Klimawandels zu reagieren und die langfristige Robustheit und Nachhaltigkeit von Bauprojekten zu erhöhen.

Ein solches generalisiertes Modell, das alle gängigen Materialien berücksichtigt, hätte auch einen großen Mehrwert für das Verwalten kommunaler Immobilienportfolios.

Vermeintliche Einsparungsmaßnahmen der Kommunen im Bereich der Gebäudeinstandhaltung führten in den letzten Jahren zu einem riesigen, progressiv ansteigenden Instandhaltungs- und Sanierungsstau. Eine ökonomisch vorausschauende Gebäudewirtschaft wurde häufig nicht betrieben, sondern Instandsetzungen erst nach bereits eingetretenen Schäden durchgeführt [194, 195].

Basierend auf den Erkenntnissen der Firma LifeCycle-Competence, die sich auf die Instandhaltung von kommunalen Portfolios spezialisiert hat, zeigt sich erfahrungsgemäß, dass eine proaktive Instandhaltung bzw. eine Priorisierung der Instandhaltung aufgrund der oft unzureichenden Kenntnisse über den Zustand einzelner Gebäude nur schwer realisierbar ist.

In der Folge des Zerfalls viele Liegenschaften und Gebäude ergeben sich für die Instandsetzung höherer Kosten [195].

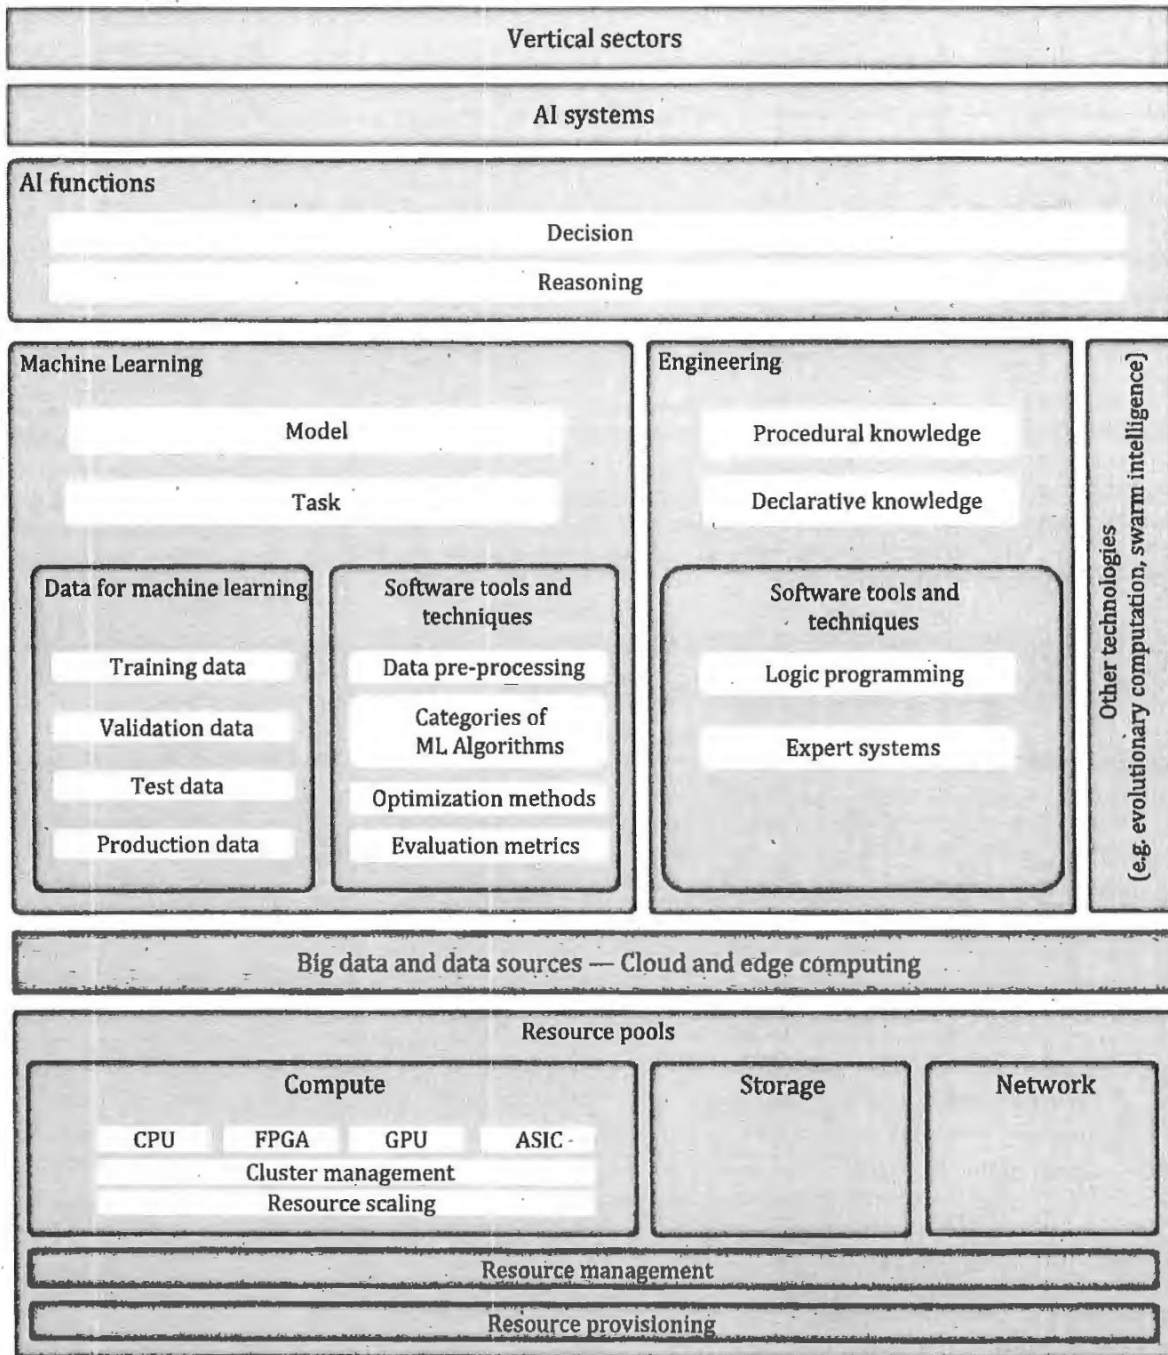
Am Beispiel der Landeshauptstadt Mainz mit einer Einwohnerzahl von ca. 217.000 [196] und einem Haushaltsansatz von 26.800.000 € [197] (S. 9) für den Bereich der Instandhaltung zur Werterhaltung der kommunalen Gebäude wird deutlich, dass erhebliche finanzielle Mittel in die Instandhaltung investiert werden.

Es ist daher wissenschaftlich zu prüfen, ob die Vernachlässigung der Instandsetzung durch die Kommunen ausschließlich auf Sparmaßnahmen oder auch auf Unkenntnis über den Zustand der Gebäude zurückzuführen ist.


Angesichts der beträchtlichen finanziellen Mittel, die für die Instandhaltung aufgewendet werden, könnten bereits geringfügige Verbesserungen der Zustandsprognose zu erheblichen Einsparungen bei den Instandhaltungskosten führen.

13 Anhang

13.1 Anhang A



Anhang A 1: AI ecosystem (ISO IEC 22989) (Quelle: [60] S. 44)




Anhang A 2: Examples of various categories of ML algorithms (Quelle: [80] S. 10)

| Kostengruppe (KG) | | | |
|--------------------------|---------------------------|---|-----------------------------------|
| 3000 | Bauwerk – Baukonstruktion | | |
| | 3100 | Baugrube, Erdbau | |
| | | 3110 | Herstellung |
| | | 3120 | Umschließung |
| | | 3130 | Wasserhaltung |
| | | 3140 | Vortrieb |
| | | 3190 | Sonstiges zur KG 310(0) |
| | 3200 | Gründung, Unterbau | |
| | | 3210 | Baugrundverbesserung |
| | | 3220 | Flachgründungen und Bodenplatten |
| | | 3230 | Tiefgründungen |
| | | 3240 | Gründungsbeläge |
| | | 3250 | Abdichtung und Bekleidung |
| | | 3260 | Dränagen |
| | | 3290 | Sonstiges zur KG 320(0) |
| | 3300 | Außenwände/Vertikale Baukonstruktionen, außen | |
| | | 3310 | Tragende Außenwände |
| | | 3320 | Nichttragende Außenwände |
| | | 3330 | Außenstützen |
| | | 3340 | Außenwandöffnungen (Durchschnitt) |
| | | 3341 | Außenfenster |
| | | 3342 | Außentüren |

| | | |
|--|------|---|
| | 3350 | Außenwandbekleidungen, außen (Durchschnitt) |
| | 3351 | Putz |
| | 3352 | Mauerwerk |
| | 3353 | Platten bzw. Stein |
| | 3354 | Holz |
| | 3355 | Metall |
| | 3360 | Außenwandbekleidungen, innen |
| | 3370 | Elementierte Außenwandkonstruktionen |
| | 3380 | Lichtschutz zur KG 300(0) |
| | 3390 | Sonstiges zur KG 300(0) |
| | 3400 | Innenwände/Vertikale Baukonstruktionen, innen |
| | 3410 | Tragende Innenwände |
| | 3420 | Nichttragende Innenwände |
| | 3430 | Innenstützen |
| | 3440 | Innenwandöffnungen (Durchschnitt) |
| | 3341 | Innentüren |
| | 3342 | Innenfenster |
| | 3450 | Innenwandbekleidung (Durchschnitt) |
| | 3451 | Beschichtung |
| | 3452 | Putz |
| | 3453 | Bekleidung |
| | 3454 | Tapeten |
| | 3460 | Elementierte Innenwandkonstruktionen |
| | 3461 | einfach |
| | 3462 | hochwertig |
| | 3470 | Lichtschutz zur KG 340(0) |
| | 3490 | Sonstiges zur KG 340(0) |
| | 3500 | Decken/Horizontale Baukonstruktionen |
| | 3510 | Deckenkonstruktionen |
| | 3520 | Deckenöffnungen |
| | 3530 | Deckenbeläge |
| | 3540 | Deckenbekleidungen |


| | | |
|--|------|-----------------------------------|
| | 3550 | Elementierte Deckenkonstruktionen |
| | 3590 | Sonstiges zur KG 350(0) |
| | 3600 | Dächer |
| | 3610 | Dachkonstruktionen |
| | 3620 | Dachöffnungen |
| | 3630 | Dachbeläge (Durchschnitt) |
| | 3631 | Flachdachabdichtung |
| | 3632 | Dachdeckung |
| | 3633 | Attikaabdeckung |
| | 3634 | Entwässerung |
| | 3640 | Dachbekleidungen |
| | 3650 | Elementierte Dachkonstruktionen |
| | 3660 | Lichtschutz zur KG 360(0) |
| | 3690 | Sonstiges zur KG 360(0) |

Anhang A 3: Kostengliederung von KG 300(0) bis einschließlich KG 360(0) nach DIN 276 (modifiziert) mit vier Ebenen (Quelle: eigene Darstellung nach [19])



Anhang A 4: Ersatzzeitpunkte für das Bauteil „Verputz“ (Quelle: [55] S. 17)


nach Globus der Naturgefahren, © 2009 Münchener Rückversicherungsgesellschaft




VG250, DLM1000 © Bundesamt für Kartographie und Geodäsie (www.bkg.bund.de)

Hydrotec, Juli 2010

Anhang A 5: Hagelzonen nach Münchener Rück 2009 (Quelle: [134] S. 64 nach [135])



Anhang A 6: Hagelschlagrisiko 1980 - 1998 nach Schadenssätzen (Quelle: [7] S. 218 nach [136])



Anhang A 7: BPMN 2.0 Ablaufdiagramm der Inspektion für Gebäude in dieser Arbeit (Quelle: eigene Darstellung)



BTE-Lebensdauer katalog

Die veröffentlichten Tabellenwerte sind Richtwerte, die von Einzelfällen zum Teil weit abweichen können.
Die Vorbemerkungen sind zwingend zu beachten.

Stand:14.3.2008

| Bauteilgliederung | | Empfehlung der BTE Arbeitsgruppe | | | Statistische Auswertungen der... Umfrage BTE Auswertung | | | bisherigen Veröffentlichungen | | |
|----------------------------------|--|----------------------------------|--------|----------|---|--------|----------|-------------------------------|---------|-----------|
| | |]von [3] | MW [4] | bis[[5] |]von [6] | MW [7] | bis[[8] |]von [9] | MW [10] | bis[[11] |
| [1] | [2] | | | | | | | | | |
| Bauwerk - Baukonstruktion | | | | | | | | | | |
| 1 | Gründung | | | | | | | | | |
| 1.1 | Betonfundament | 80 | 100 | 120 | | | | | | |
| 1.1.1 | Einzelfundament | | 100 | | 67 | 90 | 128 | | 90 | |
| 1.1.2 | Streifenfundament | | 100 | | 69 | 90 | 124 | | 90 | |
| 1.1.3 | Plattenfundament | | 100 | | 61 | 87 | 117 | | 90 | |
| 1.2 | Bauwerksabdichtung erdberührter Bauteile | 25 | 40 | 60 | | | | | | |
| 1.2.1 | gegen nichtdrückendes Wasser | | 40 | | 25 | 41 | 58 | | 40 | |
| 1.2.2 | gegen drückendes Wasser | | 40 | | 24 | 40 | 56 | | 40 | |
| 1.3 | Dränanlagen | 25 | 40 | 50 | | | | | | |
| 1.3.1 | Leitungen | | 40 | | 22 | 34 | 41 | | 30 | |
| 1.3.2 | Schächte | | 40 | | 29 | 42 | 51 | | 40 | |
| 2 | Außenwände | | | | | | | | | |
| 2.0 | Außenwände, unbekleidet, sichtbare Konstruktion | | | | | | | | | |
| 2.0.1 | Fachwerk, Holz | 20 | 30 | 40 | | | | | | |
| 2.0.2 | Betonwand | 30 | 55 | 80 | | | | | | |
| 2.0.3 | Sichtmauerwerk | 40 | 60 | 80 | | | | | | |
| 2.1 | Wände und Stützen, bekleidet | | | | | | | | | |
| 2.1.1 | Beton | | 90 | | 73 | 88 | 120 | | 95 | |
| 2.1.2 | Ziegel | | 100 | | 80 | 97 | 130 | | 93 | |
| 2.1.3 | Stein (sonstiger) | | 90 | | 64 | 92 | 119 | | 95 | |
| 2.1.3a | Porenbeton | | 80 | | | | | | | |
| 2.1.4 | Holz hart | | 75 | | 54 | 72 | 84 | | 83 | |
| 2.1.5 | Holz weich | | 50 | | 37 | 48 | 74 | | 50 | |
| 2.2 | Bekleidungen tragender Konstruktionen | | | | | | | | 35 | |
| 2.2.1 | Klinker, Verblender | | 90 | | 80 | 89 | 130 | | 80 | |
| 2.2.2 | Vefugung, Sichtmauerwerk | | 50 | | 38 | 50 | 70 | | 48 | |
| 2.2.3 | Fliesen, Platten | | 40 | | 28 | 43 | 48 | | 40 | |
| 2.2.4 | Außenputz, mineralisch/organisch | 35 | 50 | 65 | 37 | 47 | 58 | | 41 | |
| 2.2.6 | Holz weich | | 30 | | 22 | 32 | 42 | | 35 | |
| 2.2.7 | Naturstein | | 70 | | 67 | 73 | 109 | | 80 | |
| 2.2.8 | Faserzement | | 35 | | 32 | 46 | 48 | | 70 | |
| 2.2.9 | Stahlblech | 30 | 40 | 50 | 30 | 41 | 48 | | 48 | |
| 2.2.10 | Kunststoff | 25 | 30 | 40 | 25 | 33 | 38 | | 45 | |
| 2.2.11 | Glas | | 40 | | 32 | 42 | 56 | | 40 | |
| 2.2.12 | Kupferblech | | 50 | | 34 | 55 | 60 | | 50 | |
| 2.2.13 | Aluminium | | 50 | | 30 | 45 | 50 | | 80 | |

BTE-Arbeitsgruppe
LEBENSDAUER VON BAUTEILEN

AGETHEN-FRAHM-RENTZ-THEES

| Bauteilgliederung | [3] Umfrage BTE | | | [4] Klocke | | | [5] IFB 2004 | | | [6] Nutz-Katalog öbuv Öst. | | | [7] WertR | | | [8] Schmitz | | | [9] LB | | | [10] IEMB | | | [11] IFB-Umfrage WU | | | | | | | | | | | |
|---------------------------|---|----|-----|---------------|----|-----|--------------------|----|-----|----------------------------------|----|-----|--------------|----|-----|----------------|----|-----|-----------|----|-----|--------------|----|-----|---------------------------|----|-----|----|--|--|----|--|--|----|--|--|
| | von | MW | bis | von | MW | bis | von | MW | bis | von | MW | bis | von | MW | bis | von | MW | bis | von | MW | bis | von | MW | bis | von | MW | bis | | | | | | | | | |
| Bauwerk - Baukonstruktion | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1 | Gründung | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1.1 | Betonfundament | | | 80 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1.1.1 | Einzelfundament | | | | | | 80 | | | | | | | | | >50 | | | 100 | | | 100 | | | 80 | | | | | | | | | | | |
| 1.1.2 | Streifenfundament | | | | | | 80 | | | | | | | | | >50 | | | 100 | | | 100 | | | 80 | | | | | | | | | | | |
| 1.1.3 | Plattenfundament | | | | | | 80 | | | | | | | | | >50 | | | 100 | | | 100 | | | 80 | | | | | | | | | | | |
| 1.2 | Bauwerksabdichtung erdberührter Bauteile | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1.2.1 | gegen nichtdrückendes Wasser | | | | | | 40 | | | 20 | | | 80 | | | | | | 31 | | | 41 | | | 50 | | | 40 | | | 40 | | | 40 | | |
| 1.2.2 | gegen drückendes Wasser | | | | | | 40 | | | | | | | | | | | | 31 | | | 41 | | | 50 | | | | | | | | | 40 | | |
| 1.3 | Dränanlagen | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1.3.1 | Leitungen | | | | | | 30 | | | 15 | | | 100 | | | | | | | | | | | | | | | | | | | | | 30 | | |
| 1.3.2 | Schächte | | | | | | 40 | | | 35 | | | 80 | | | | | | | | | | | | | | | | | | | | | 40 | | |
| 2 | Außenwände | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 2.1 | Wände und Stützen, bekleidet | | | 80 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 2.1.1 | Beton | | | | | | 80 | | | | | | | | | | | | | | | 100 | | | 120 | | | 80 | | | | | | | | |
| 2.1.2 | Ziegel | | | | | | 80 | | | 100 | | | | | | >50 | | | 90 | | | 120 | | | 80 | | | | | | | | | | | |
| 2.1.3 | Stein (sonstiger) | | | | | | 80 | | | 100 | | | | | | >50 | | | 100 | | | 120 | | | 80 | | | | | | | | | | | |
| 2.1.4 | Holz hart | | | | | | 80 | | | | | | | | | >50 | | | 70 | | | 100 | | | 80 | | | | | | | | | | | |
| 2.1.5 | Holz weich | | | | | | 30 | | | | | | | | | | | | | | | 70 | | | | | | | | | | | | | | |
| 2.2 | Bekleidungen | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 2.2.1 | Klinker | | | | | | 80 | | | | | | | | | | | | | | | | | | | | | | | | | | | 80 | | |
| 2.2.2 | Vefugung, Sichtmauerwerk | | | | | | 40 | | | 10 | | | 20 | | | 30 | | | | | | 90 | | | | | | | | | 40 | | | | | |
| 2.2.3 | Fliesen, Platten | | | | | | 40 | | | 10 | | | 20 | | | 30 | | | | | | 60 | | | | | | | | | 40 | | | | | |
| 2.2.4 | Putz mineralisch | | | 40 | | | 80 | | | 50 | | | 30 | | | 45 | | | 60 | | | | | | 30 | | | 30 | | | 50 | | | | | |
| 2.2.5 | Putz Kunststoff | | | | | | 40 | | | | | | | | | | | | | | | 50 | | | 40 | | | 40 | | | | | | | | |
| 2.2.6 | Holz weich | | | | | | 30 | | | 30 | | | 40 | | | 50 | | | | | | 45 | | | 30 | | | 30 | | | | | | | | |
| 2.2.7 | Naturstein | | | | | | | | | 60 | | | | | | | | | | | | 80 | | | | | | | | | | | | | | |
| 2.2.8 | Faserzement | | | | | | 60 | | | 40 | | | | | | | | | | | | 80 | | | 80 | | | 60 | | | | | | | | |
| 2.2.9 | Stahlblech | | | | | | 40 | | | 40 | | | | | | | | | | | | 55 | | | 55 | | | 40 | | | | | | | | |

Zusammenstellung bisheriger Veröffentlichungen

1/13

Anhang A 10: Zusammenstellung bisheriger Veröffentlichungen zu Lebensdauern der BTE-Arbeitsgruppe (1/13) (1. Auflage, Stand 14.03.2008) (Quelle: [8] S.1)

7. Tabellenwerte und BTE-Lebensdauer katalog

Die veröffentlichten Tabellenwerte sind Richtwerte, die von Einzelfällen zum Teil weit abweichen können.

| Bauteilgliederung | | Empfehlung der BTE Arbeitsgruppe | | |
|-------------------|--|-------------------------------------|---------------------|------------|
| | |] von [3] | Mittelwert [4] | bis [5] |
| [1] | [2] | | | |
| 1 | Gründung | | | |
| 1.1 | Betonfundament | 80 | 100 | 120 |
| 1.1.1 | Einzelfundament | | 100 | |
| 1.1.2 | Streifenfundament | | 100 | |
| 1.1.3 | Plattenfundament | | 100 | |
| 1.2. | Bauwerksabdichtung erdberührter Bauteile | 25 | 40 | 60 |
| 1.2.1 | gegen nichtdrückendes Wasser | | 40 | |
| 1.2.2 | gegen drückendes Wasser | | 40 | |
| 1.3. | Dränanlagen | 25 | 40 | 50 |
| 1.3.1 | Leitungen | | 40 | |
| 1.3.2 | Schächte | | 40 | |
| 2 | Außenwände | | | |
| 2.0 | Außenwände, unbekleidet, sichtbare Konstruktion | | | |
| 2.0.1 | Fachwerk, Holz | | 70 | |
| 2.0.2 | Betonwand | | 40 | |
| 2.0.3 | Sichtmauerwerk | | 60 | |
| 2.1 | Wände und Stützen, bekleidet | | | |
| 2.1.1 | Beton | | 90 | |
| 2.1.2 | Ziegel | | 100 | |
| 2.1.3 | Stein (sonstiger) | | 90 | |
| 2.1.3a | Porenbeton | | 80 | |
| 2.1.4 | Holz hart | | 80 | |
| 2.1.5 | Holz weich | | 50 | |
| 2.2 | Bekleidungen tragender Konstruktionen | | | |
| 2.2.1 | Klinker, Verblender | | 90 | |
| 2.2.2 | Verfugung, Sichtmauerwerk | | 50 | |
| 2.2.3 | Fliesen, Platten | | 40 | |
| 2.2.4 | Außenputz, mineralisch/organisch | | 50 | |
| 2.2.6 | Holz weich | | 30 | |
| 2.2.7 | Naturstein | | 70 | |
| 2.2.8 | Faserzement | | 40 | |
| 2.2.9 | Stahlblech | | 40 | |
| 2.2.10 | Kunststoff | | 30 | |
| 2.2.11 | Glas | | 40 | |

Anhang A 11: Empfehlungen für Lebensdauern der BTE-Arbeitsgruppe (2. Auflage, Stand August 2019) (Quelle: [12] S. 24)


| Durchschnittliche Nutzungsdauer bis zum Ersatz von Bauteilen nach Erstellungsjahr | | | | | | |
|---|----------------------|-------------|--------------------------|---------------------|----------------------|-------------|
| Verputz | 1928–38 | | 52 Jahre | Fenster | 1928–38 | 55 Jahre |
| | 1938–48 | | 50 Jahre | | 1938–48 | 47 Jahre |
| | 1948–58 | | 36 Jahre | | 1948–58 | 40 Jahre |
| | 1958–68 | | 30 Jahre | | 1958–68 | 35 Jahre |
| Fassadendekoration * | | 35–85 Jahre | Wetter- und Sonnenschutz | | | |
| Balkon, Loggia * | | 45–85 Jahre | 1928–38 | | 57 Jahre | |
| Aussentüre, Tor * | | 25–75 Jahre | 1938–48 | | 42 Jahre | |
| | | | 1948–58 | | 32 Jahre | |
| Steildach | 1928–38 extrapoliert | | 55–80 Jahre | Küche | 1948–58 | 36 Jahre |
| | 1938–48 extrapoliert | | 55–75 Jahre | | 1958–68 | 36 Jahre |
| Flachdach | 1948–58 | | 38 Jahre | Sanitärinstallation | 1938–48 | 37 Jahre |
| | 1958–68 | | 24 Jahre | | 1948–58 | 37 Jahre |
| | 1968–78 extrapoliert | | 25–30 Jahre | | 1958-68 extrapoliert | 30–35 Jahre |
| Dachabschluss | | | | | Wärmeerzeugung | |
| 1948–52 | | 35 Jahre | 1938–48 | | 35 Jahre | |
| 1953–57 | | 35 Jahre | 1948–58 | | 30 Jahre | |
| 1958–62 | | 30 Jahre | 1958–68 | | 22 Jahre | |
| 1963–67 | | 25 Jahre | | | | |

Anhang A 12: Durchschnittliche Nutzungsdauer bis zum Ersatz von Bauteilen nach Erstellungsjahr
(Quelle: [55] S.18)


| Kostengruppe | Datensätze |
|--------------|------------|
| KG 3310 | 153x13 |
| KG 3341 | 262x13 |
| KG 3342 | 230x13 |
| KG 3351 | 113x13 |
| KG 3370 | 91x13 |
| KG 3620 | 130x13 |
| KG 3631 | 129x13 |
| KG 3632 | 136x13 |
| KG 3633 | 165x13 |
| KG 3634 | 243x13 |

Anhang A 13: Datensätze nach Kostengruppen (Quelle: eigene Darstellung)


13.2 Anhang B




Anhang B 1: Histogramm - Datenverteilung für das Bauelement (KG) 3310 (Quelle: eigene Darstellung)




Anhang B 2: Histogramm - Datenverteilung für das Bauelement (KG) 3341 (Quelle: eigene Darstellung)




Anhang B 3: Histogramm - Datenverteilung für das Bauelement (KG) 3342 (Quelle: eigene Darstellung)




Anhang B 4: Histogramm - Datenverteilung für das Bauelement (KG) 3351 (Quelle: eigene Darstellung)




Anhang B 5: Histogramm - Datenverteilung für das Bauelement (KG) 3370 (Quelle: eigene Darstellung)




Anhang B 6: Histogramm - Datenverteilung für das Bauelement (KG) 3620 (Quelle: eigene Darstellung)




Anhang B 7: Histogramm - Datenverteilung für das Bauelement (KG) 3631 (Quelle: eigene Darstellung)




Anhang B 8: Histogramm - Datenverteilung für das Bauelement (KG) 3632 (Quelle: eigene Darstellung)



Anhang B 9: Histogramm - Datenverteilung für das Bauelement (KG) 3633 (Quelle: eigene Darstellung)




Anhang B 10: Histogramm - Datenverteilung für das Bauelement (KG) 3634 (Quelle: eigene Darstellung)




Anhang B 11: Histogramm - Datenverteilung des zusammengesetzten Datensatz (alle Kostengruppen) (Quelle: eigene Darstellung)


13.3 Anhang C




Anhang C 1: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3310 (Quelle: eigene Darstellung)



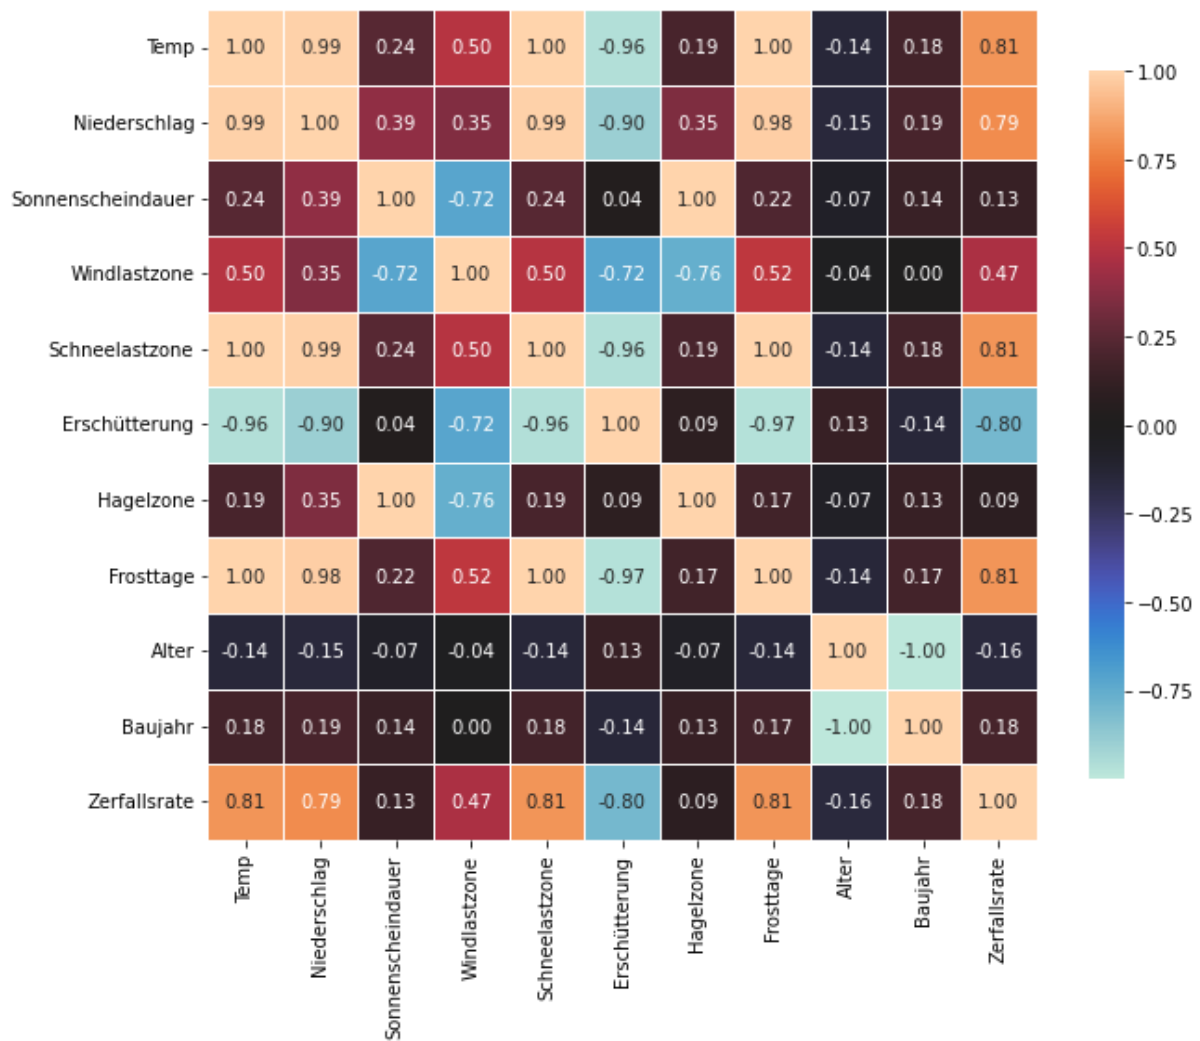
Anhang C 2: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3341 (Quelle: eigene Darstellung)




Anhang C 3: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3342
(Quelle: eigene Darstellung)



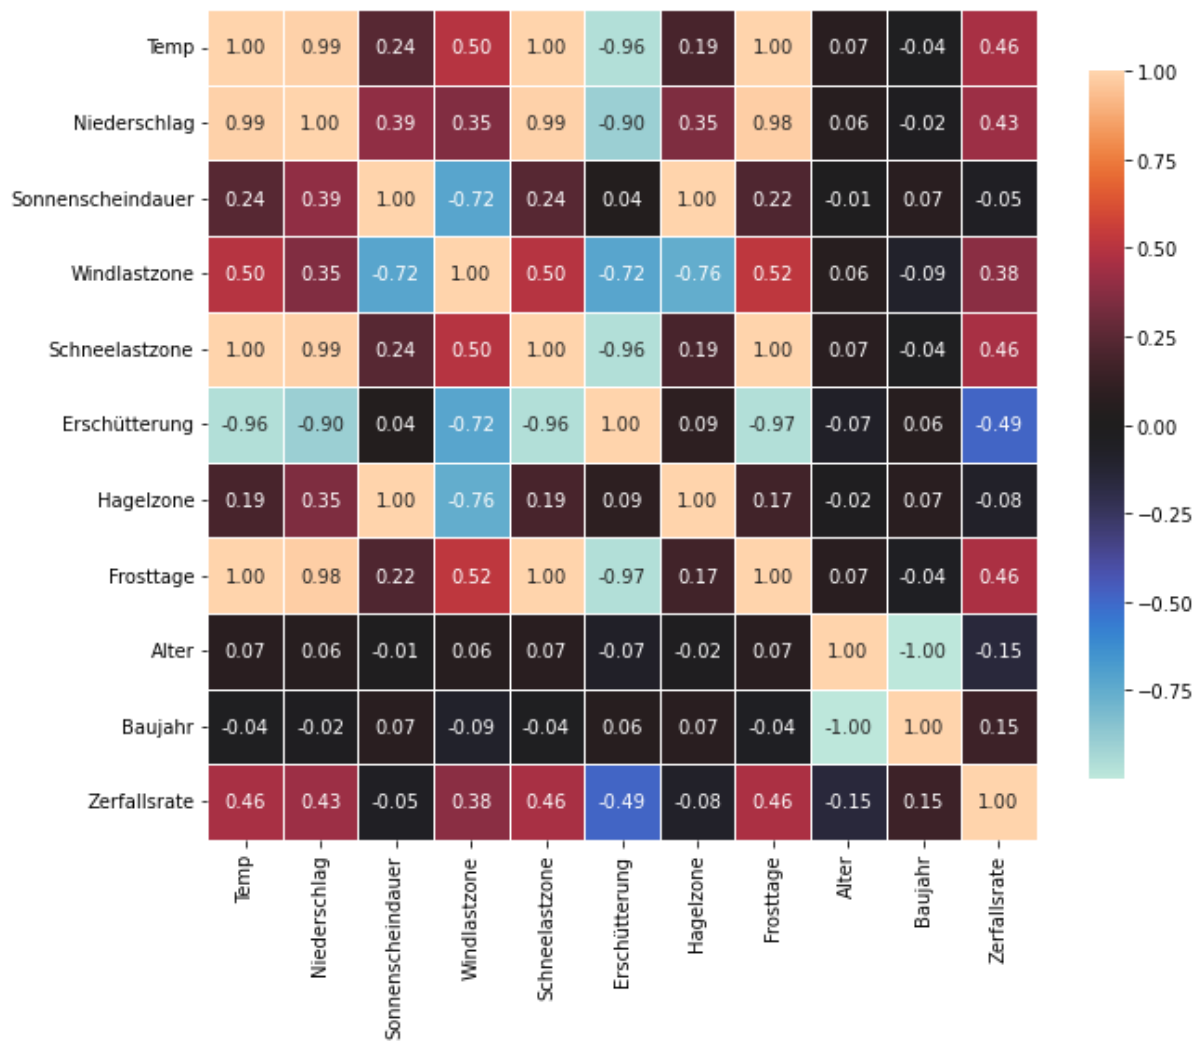
Anhang C 4: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3351 (Quelle: eigene Darstellung)




Anhang C 5: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3370
(Quelle: eigene Darstellung)




Anhang C 6: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3620 (Quelle: eigene Darstellung)




Anhang C 7: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3631
(Quelle: eigene Darstellung)




Anhang C 8: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3632
(Quelle: eigene Darstellung)




Anhang C 9: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3633
(Quelle: eigene Darstellung)




Anhang C 10: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3634
(Quelle: eigene Darstellung)




Anhang C 11: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3310
(Quelle: eigene Darstellung)



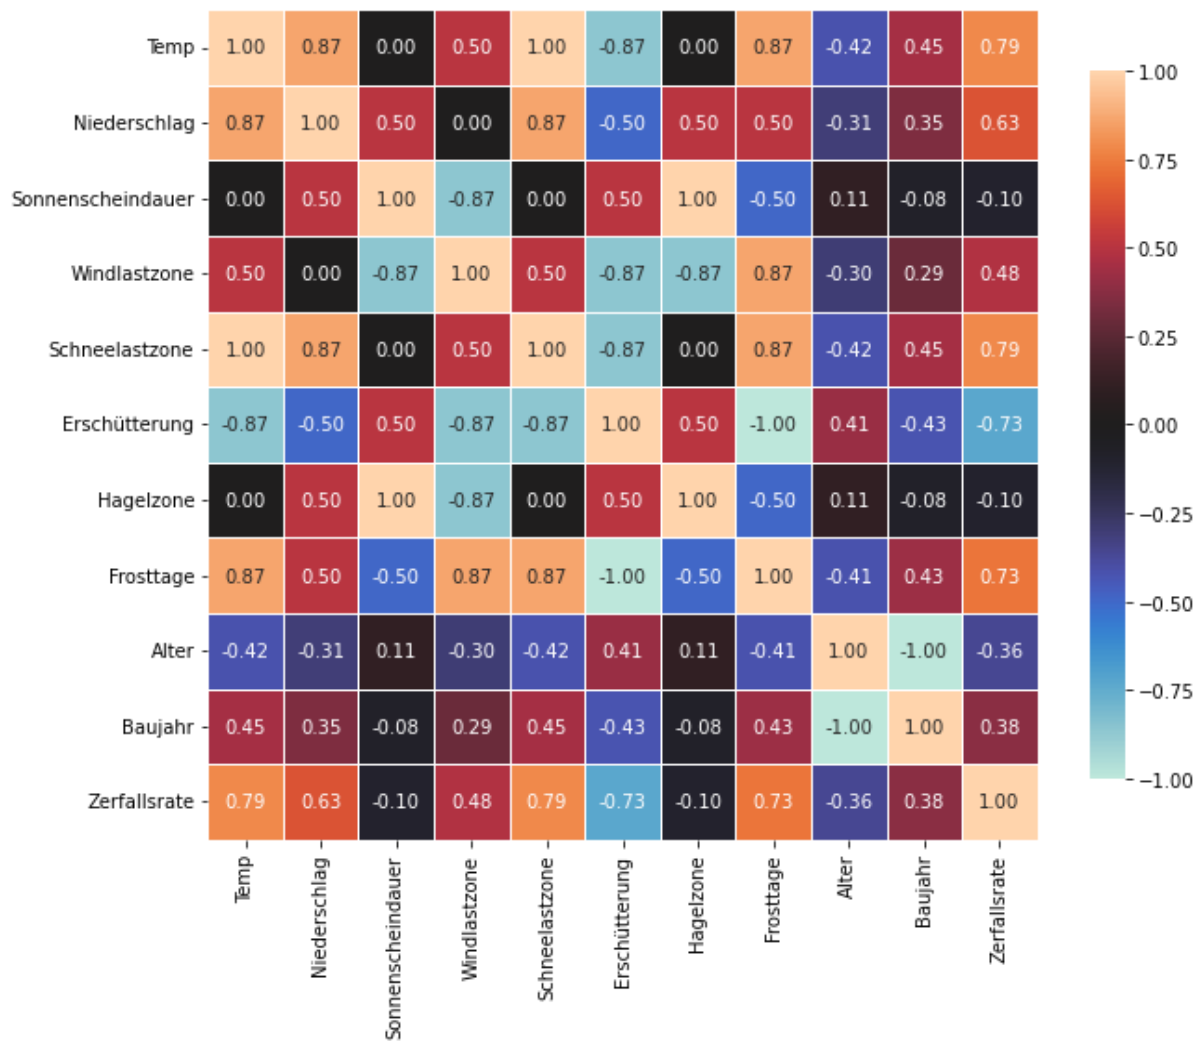
Anhang C 12: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3341
(Quelle: eigene Darstellung)




Anhang C 13: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3342
(Quelle: eigene Darstellung)



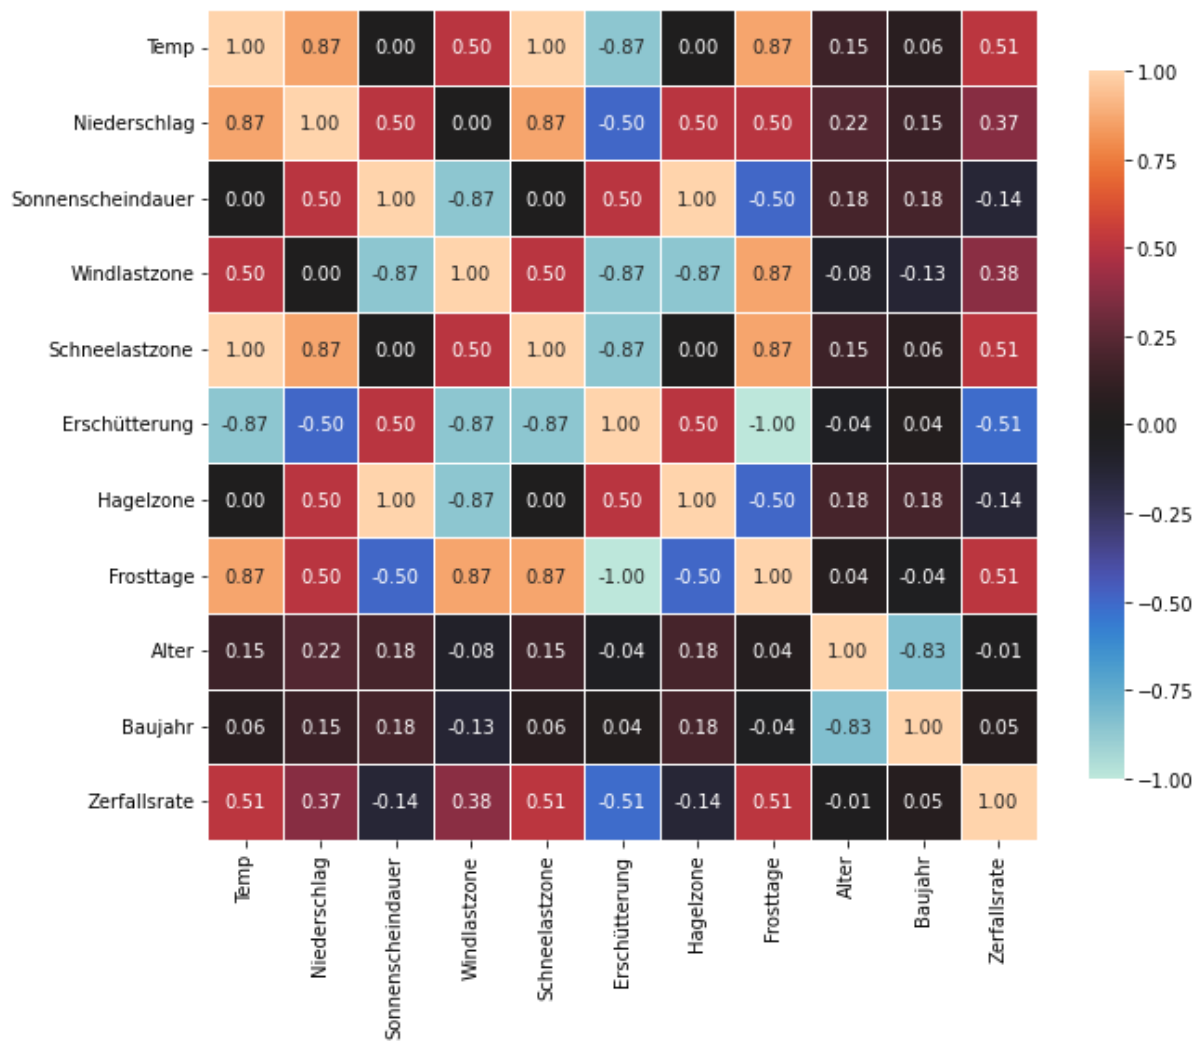
Anhang C 14: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3351
(Quelle: eigene Darstellung)




Anhang C 15: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3370 (Quelle: eigene Darstellung)



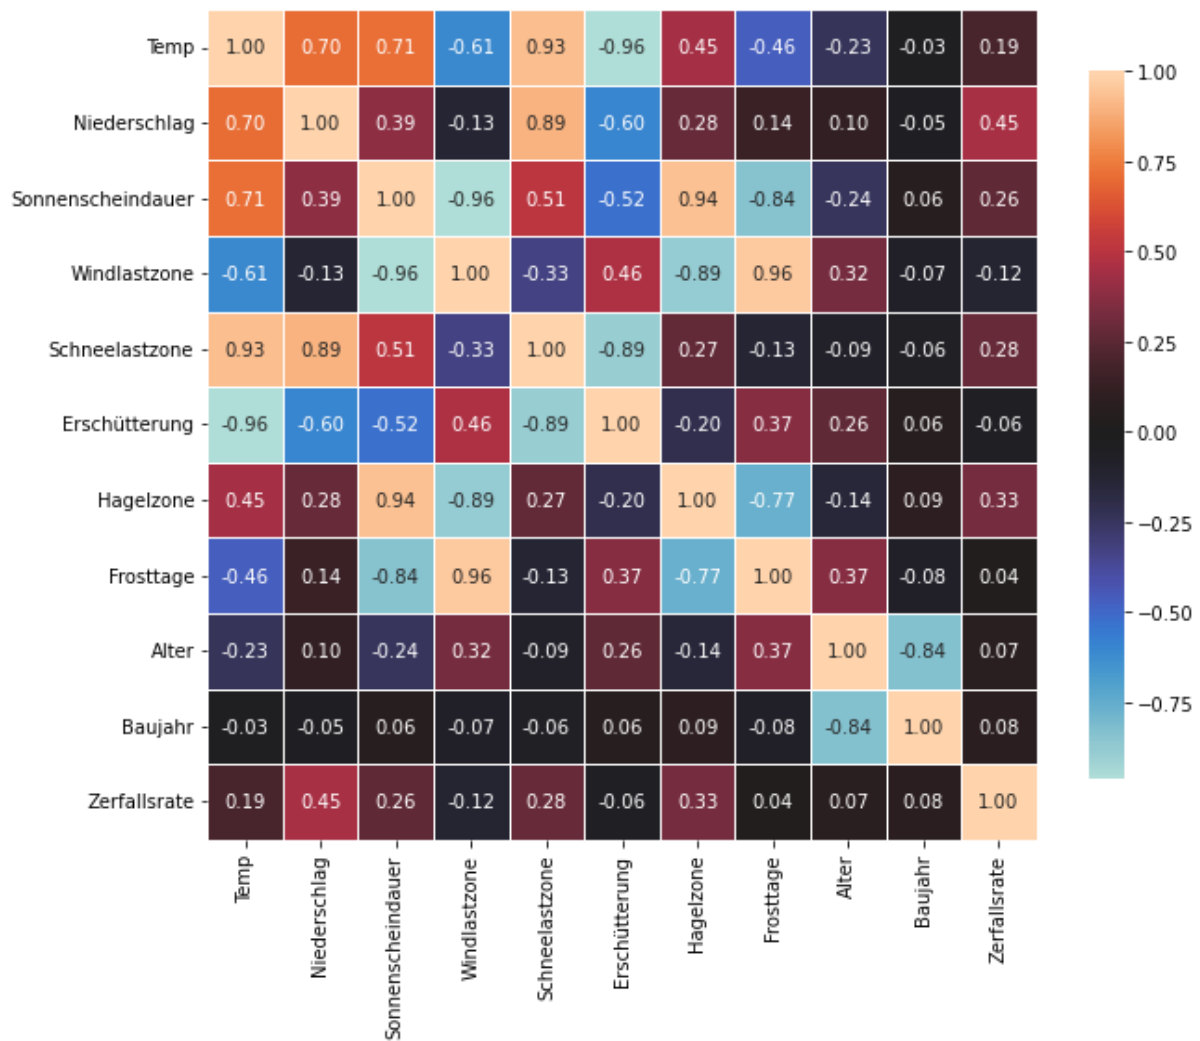
Anhang C 16: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3620 (Quelle: eigene Darstellung)




Anhang C 17: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3631
(Quelle: eigene Darstellung)



Anhang C 18: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3632
(Quelle: eigene Darstellung)



Anhang C 19: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3633
(Quelle: eigene Darstellung)



Anhang C 20: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3634
(Quelle: eigene Darstellung)

13.4 Anhang D

```
def load_my_dataset():
    with open(r'dataset_final/dataset.csv') as csv_file:
        data_file = csv.reader(csv_file)

        n_samples = 2560
        n_features = 20
        feature_names =
["Temp", "Niederschlag", "Sonnenscheindauer", "Windlastzone", "Schneelastzone",
"Erschütterung", "Hagelzone", "Frosttage", "3310", "3341", "3342", "3351", "3370",
"3620", "3631", "3632", "3633", "3634", "Alter", "Baujahr"]

        target_names = ['Zerfallsrate']
        data = np.empty((n_samples, n_features))
        target = np.empty((n_samples,), dtype=np.float64)

        for i, sample in enumerate(data_file):
            data[i] = np.asarray(sample[:-1], dtype=np.float64)
            target[i] = np.asarray(sample[-1], dtype=np.float64)

        return Bunch(data=data, target=target, feature_names=feature_names,
target_names=target_names)
```

Anhang D 1: Ausschnitt Programmiercode: Funktion load_my_dataset (Python)

Quelle: eigene Darstellung

```
metrische_features = ["Temp", "Niederschlag", "Sonnenscheindauer",
"Erschütterung", "Frosttage", "Alter", "Baujahr"]
kategoriale_features = ["Windlastzone", "Schneelastzone", "Hagelzone",
"3310", "3341", "3342", "3351", "3370", "3620", "3631", "3632", "3633",
"3634"]
metrische_data = df[metrische_features]
kategoriale_data = df[kategoriale_features]

ss = StandardScaler()
X_metrisch_scaled = ss.fit_transform(metrische_data)
X = np.hstack((X_metrisch_scaled, kategoriale_data))
```

Anhang D 2: Ausschnitt Programmiercode: Aufteilung der Features und Anwendung des StandardScalers auf die metrischen Features (Python) (Quelle: eigene Darstellung)

```

scaler_params = {
    "mean": ss.mean_.tolist(),
    "scale": ss.scale_.tolist()
}

import json
# Save the parameters to a JSON file
with open('std_scaler.json', 'w') as f:
    json.dump(scaler_params, f)

```

Anhang D 3: Ausschnitt Programmiercode: Exportieren der Scaler-Parameter als JSON-Datei (Python) (Quelle: eigene Darstellung)

```

#Neural Network Architecture
model = Sequential()
model.add(Dense(units=91, activation='relu', input_shape=(20,)))
model.add(Dense(units=62, activation='relu'))
model.add(Dense(units=44, activation='relu'))
model.add(Dense(units=21, activation='relu'))
model.add(Dense(units=79, activation='relu'))
model.add(Dense(units=1))

#Optimizer
opt = keras.optimizers.Adam(learning_rate=0.0015858034769032404)

#X,y to train,test
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=1)

#train to train,val
X_train, X_val, y_train, y_val = train_test_split(X_train, y_train,
test_size=0.2, random_state=1)

#compile
model.compile(optimizer=opt,loss='mean_squared_error',metrics=['mean_absolute_percentage_error'])

#fit
history = model.fit(X_train, y_train, epochs=150, batch_size=15,
validation_data=(X_val, y_val))

#save
model.save("OPKI.h5")

```

Anhang D 4: Architektur des neuronalen Netzwerkes (Python) (Quelle: eigene Darstellung)

```

def build_model(hp):
    model = keras.Sequential()
    model.add(keras.layers.Input(X_train.shape[1]))

    # Anzahl der Layer
    for i in range(hp.Int('num_layers', 3, 7)):

        # Anzahl der Neuronen pro Dense Layer
        model.add(keras.layers.Dense(
            units=hp.Int('units_' + str(i), 16, 256),
            activation='relu'
        ))
        # Batch-Normalization und Dropout
        # model.add(keras.layers.BatchNormalization())
        # model.add(keras.layers.Dropout(0.2))

    model.add(keras.layers.Dense(1, activation='linear'))

    # Lernrate des Optimizers
    hp_learning_rate = hp.Float("lr", min_value=1e-3, max_value=1e-2,
sampling="log")
    # Batch-Größe als Hyperparameter definieren
    hp_batch_size = hp.Choice('batch_size', values=[5,8,10,12,15,20,25])

    model.compile(optimizer=keras.optimizers.Adam(learning_rate=hp_learning_rate),
                  loss='mean_squared_error',
                  metrics=['mean_absolute_percentage_error'])
    return model

# Keras Tuner RandomSearch
tuner = RandomSearch(
    hypermodel=build_model,
    objective='mean_absolute_percentage_error',
    max_trials=50, # Anzahl der Durchläufe
    executions_per_trial=5,
    overwrite=True,
    directory='my_dir', # Verzeichnis zum Speichern der Modelle
    project_name='project_OPKI') # Projektname

# Suche nach dem besten Modell
tuner.search(X_train, y_train, epochs=150, validation_data=(X_test, y_test))

```





























Anhang D 5: Implementierung KerasTuner (Python) (Quelle: eigene Darstellung)

```

<div class="col-2">
<label for="select" class="form-label">Kostengruppe</label>
<select id="select_kg" name="select_kg" class="form-select">
<option value="1,0,0,0,0,0,0,0,0,0">Tragende Außenwände (3310)</option>
<option value="0,1,0,0,0,0,0,0,0,0">Außenwandöffnung Außentüren
(3341)</option>
<option value="0,0,1,0,0,0,0,0,0,0">Außenwandöffnung Außenfenster
(3343)</option>
<option value="0,0,0,1,0,0,0,0,0,0">Außenwandbegleitung Putz
(3351)</option>
<option value="0,0,0,0,1,0,0,0,0,0">Elementierte Außenwandbegleitung
(337)</option>
<option value="0,0,0,0,0,1,0,0,0,0">Dachöffnung (3620)</option>
<option value="0,0,0,0,0,0,1,0,0,0">Dachbeläge Flachdachabdichtung
(3631)</option>
<option value="0,0,0,0,0,0,0,1,0,0">Dachbeläge Dachdeckung (3632)</option>
<option value="0,0,0,0,0,0,0,0,1,0">Dachbeläge Attikaabdeckung (</option>
<option value="0,0,0,0,0,0,0,0,0,1">Dachbeläge Entwässerung (3634)</option>
</select>
</div>

```

Anhang D 6: One-Hot-Codierung Dropdown KG (Prototyp) (HTML) (Quelle: eigene Darstellung)

| # | Name | Typ | Kollation | Attribute | Null | Standard | Kommentare | Extra | Aktion |
|--------------------------|---|---------|-----------|-----------|------|----------|------------|-------|---|
| <input type="checkbox"/> | 1 PLZ  | int(10) | | | Nein | kein(e) | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 2 Temperatur | float | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 3 Niederschlag | float | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 4 Sonnenscheindauer | float | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 5 Windlastzone | int(1) | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 6 Schneelastzone | int(1) | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 7 Erschuetterung | float | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 8 Hagelzone | float | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |
| <input type="checkbox"/> | 9 Frosttage | int(3) | | | Ja | NULL | | |  Bearbeiten  Löschen  Mehr |

Anhang D 7: Struktur Tabelle der MySQL-Datenbank für die Umwelteinflüsse (Quelle: eigene Darstellung)


```

function scaleData($metrische_features , $scaler_params) {
    $mean = $scaler_params['mean'];
    $scale = $scaler_params['scale'];

    foreach ($metrische_features as &$sample) {
        for ($i = 0; $i < count($sample); $i++) {
            $sample[$i] = ($sample[$i] - $mean[$i]) / $scale[$i];
        }
    }
    return $metrische_features ;
}

```

Anhang D 8: Skalierung der Daten mit den StandardScaler-Parametern aus der JSON-Datei (Prototyp) (PHP) (Quelle: eigene Darstellung)

```

<script>
(async () => {

// Laden des TensorFlow-Modelles (Format: JSON)
const model = await tf.loadLayersModel('scripts/models/model.json');

// Hole den Wert des Elements mit der ID 'merged_array' und binde diesen an
die Variable 'elem'
var elem = document.getElementById(merged_array).value;

// Parse den Wert aus elem als JSON und speichere ihn im Array 'array'
const array = JSON.parse(elem);

// Erstelle einen 2D-Tensor 'xs' aus dem 'array'
const xs = tf.tensor2d([array]);

// Führe eine Vorhersage mit dem Modell für 'xs' durch und binde das
Ergebnis an die Variable 'y'
var y = model.predict(xs);

// Extrahiere die Werte aus dem Tensor 'y' und speichere sie im Array
'values'
const values = y.dataSync();

// Konvertiere 'values' in ein JavaScript-Array 'output'
const output = Array.from(values);

// Setze den Wert im Array 'output' als Wert des Elements mit der ID
'ergebnis'
document.getElementById('ergebnis').value = output[0];
})();
</script>

```

Anhang D 9: Laden und Ausführen des TensorFlow-Modelles (kommentiert) (Prototyp) (JS) (Quelle: eigene Darstellung)

14 Abbildungsverzeichnis

| | |
|---|----|
| Abbildung 1: Lebenszykluskosten von Wohnimmobilien..... | 1 |
| Abbildung 2: Lebensdauerschätzungen aus der Literatur am Beispiel Kunststofffenster | 3 |
| Abbildung 3: Benchmark-Sättigung im Laufe der Zeit für beliebte Benchmark-Datasets, normalisiert mit einer Ausgangsleistung von minus eins und einer menschlichen Leistung von null | 5 |
| Abbildung 4: Grafische Darstellung des Abnutzungsvorrates in der DIN 31051..... | 10 |
| Abbildung 5: Leistungsbereiche des Gebäudemanagements nach DIN 32736..... | 11 |
| Abbildung 6: Übersicht der ersten Ebene der Instandhaltungsarten nach DIN EN 13306:2018-02..... | 13 |
| Abbildung 7: Unterteilung der Instandhaltung nach DIN 31051:2019-06..... | 13 |
| Abbildung 8: Exemplarische Darstellung einer Inspektion | 15 |
| Abbildung 9: Modernisierung als Vereinigungsmenge der Änderung und Verbesserung | 18 |
| Abbildung 10: Grafische Darstellung der Wartung..... | 20 |
| Abbildung 11: Unterteilung der Instandhaltung nach DIN 31051..... | 21 |
| Abbildung 12: BPMN 2.0 Ablaufdiagramm der Inspektion für Gebäude in dieser Arbeit | 21 |
| Abbildung 13: Vereinfacht dargestellter Lebenszyklus eines Gebäudes | 22 |
| Abbildung 14: Themenbereiche der DIN ISO 15686 zur Lebensdauerplanung von Gebäuden (Stand 03/2023)..... | 25 |
| Abbildung 15: Grafische Darstellung des Abnutzungsvorrates | 27 |
| Abbildung 16: Skizze der Klassifizierung nach Krug..... | 28 |
| Abbildung 17: Alterungsverhalten und Restlebensdauer am Beispiel Steildach (Ziegel aus Ton | 29 |
| Abbildung 18: Einflussfaktoren beeinflussen das Alterungsverhalten von Bauteilen | 30 |
| Abbildung 19: Agenten Paradigma (ISO IEC 22989) – goal-based agent..... | 33 |
| Abbildung 20: Artificial Intelligence (AI) mit den Teilgebieten Machine Learning (ML) und der Teilmenge Deep Learning (DL) | 34 |
| Abbildung 21: Artificial Intelligence (AI) mit der Schnittmenge Machine Learning (ML) und der Teilmenge Deep Learning (DL) | 34 |
| Abbildung 22: Zusammenhänge zwischen Machine Learning und Deep Learning | 36 |
| Abbildung 23: Beispiel für eine Clusterbildung (K-means-Clustering) | 38 |
| Abbildung 24: Ausreißer (Outlier) am Beispiel einer Regression | 39 |
| Abbildung 25: Foto einer Frau, erzeugt durch eine AI | 42 |
| Abbildung 26: Foto einer Frau, erzeugt durch eine AI | 42 |
| Abbildung 27: Elemente des Systems "Machine Learning" nach ISO/IEC 23053:2022..... | 43 |

| | |
|---|----|
| Abbildung 28: ML-Methoden, kategorisiert als supervised ML, unsupervised ML und reinforcement ML nach der ISO/IEC 23053..... | 45 |
| Abbildung 29: Erstellung eines ML-Modells mit Supervised ML..... | 46 |
| Abbildung 30: Ablauf des Trainings eines Modells (Supervised Learning) | 47 |
| Abbildung 31: Erstellung eines ML-Modells mit Unsupervised ML..... | 48 |
| Abbildung 32: Typischer Reinforcement Learning Prozess..... | 49 |
| Abbildung 33: Beispiel für skalierte Daten | 51 |
| Abbildung 34: Beispiel für normalisierte Daten | 51 |
| Abbildung 35: Abstrahiertes Beispiel für labeled Data | 52 |
| Abbildung 36: Aufbau einer menschlichen Nervenzelle (Neuron) | 54 |
| Abbildung 37: Diagramm einer McCulloch-Pitts-Zelle nach Minsky | 55 |
| Abbildung 38: Vereinfachte Darstellung eines Neurons | 57 |
| Abbildung 39: Skizze der Identitätsfunktion | 61 |
| Abbildung 40: Skizze der Schwellenwertfunktion mit der Schwelle $\theta = 0$ | 61 |
| Abbildung 41: Beispiel mit Werten eines Perzeptrons (zweischichtiges Neuron mit Schwellenwertfunktion) | 62 |
| Abbildung 42: Skizze der logistischen Funktion | 63 |
| Abbildung 43: Skizze der ReLU-Aktivierungsfunktion | 64 |
| Abbildung 44: Bias-Neuronen Beispiel (letzter Eingang) | 66 |
| Abbildung 45: Bias-Neuronen Beispiel (erster Eingang) | 66 |
| Abbildung 46: Beispiel für ein einschichtiges Netz (Perzeptron) | 67 |
| Abbildung 47: Beispiel für ein unvollständig verbundenes zweischichtiges Netz | 67 |
| Abbildung 48: Beispiel für ein vollständig verbundenes zweischichtiges Netz | 67 |
| Abbildung 49: Screenshot der Dokumentation von scikit-learn (regression metrics)..... | 72 |
| Abbildung 50: Trainings and Validation Loss - Kurve (MSE) | 72 |
| Abbildung 51: Beispiel für Überanpassung (Overfitting) | 73 |
| Abbildung 52: Nutzungsdauern von Bauteilen für Lebenszyklusanalysen nach Bewertungssystem Nachhaltiges Bauen (BNB) (2017)..... | 90 |
| Abbildung 53: Verlauf des Zustandes eines Bauteiles unter äußeren Einflüssen | 91 |
| Abbildung 54: Räumliche und zeitliche Skalierung des Klimas mit Angabe der Klima-Art und der örtlichen Ausdehnung..... | 97 |
| Abbildung 55: Allgemeine Grenzwerte der Wegamplitude für Erschütterungen | 98 |
| Abbildung 56: Erdbebenzonen in Deutschland nach der DIN EN 1998-1/NA:2021-07 - mittlere Wiederkehrperiode von 475 Jahren (Dlubal Geo-Zonen-Tool für Lastermittlung) | 99 |

| | |
|--|-----|
| Abbildung 57: Übersichtskarte zur Schlagregenbeanspruchung in der Bundesrepublik Deutschland nach den Daten des Deutschen Wetterdienstes | 101 |
| Abbildung 58: Hagelzonen nach Münchener Rück 2009 | 102 |
| Abbildung 59: Hagelschlagrisiko 1980 - 1998 nach Schadenssätzen | 102 |
| Abbildung 60: Luftdaten des Umweltbundesamtes nach Stationen | 103 |
| Abbildung 61: Erweiterte Schneelastzonen in Deutschland nach der DIN EN 1991-1-3/NA (Dlubal Geo-Zonen-Tool für Lastermittlung) | 105 |
| Abbildung 62: Jahresmittel 2011 - 2020 Globalstrahlung [kWh/m ²]..... | 107 |
| Abbildung 63: Sonnenscheindauer im Jahresmittel 2019 Deutschland [h]..... | 107 |
| Abbildung 64: Erweiterte Windzonen in Deutschland nach der DIN EN 1991-1-4/NA:2010-12 (Dlubal Geo-Zonen-Tool für Lastermittlung) | 109 |
| Abbildung 65: Auswirkung der Instandhaltungsqualität auf den Abbau des Abnutzungsvorrates | 110 |
| Abbildung 66: Ausschnitt der Karte von Deutschland – Markierung der ausgewählten Orte | 118 |
| Abbildung 67: Plot Spektrale Antwortbeschleunigung für den Standort 1 (475a) | 119 |
| Abbildung 68: Plot Spektrale Antwortbeschleunigung für den Standort 2 (475a) | 120 |
| Abbildung 69: Plot Spektrale Antwortbeschleunigung für den Standort 3 (475a) | 121 |
| Abbildung 70: Plot Spektrale Antwortbeschleunigung für den Standort 4 (475a) | 122 |
| Abbildung 71: Ausschnitt der Struktur der Bauelemente der Gebäude in dysisko | 125 |
| Abbildung 72: Ausschnitt der Darstellung der Bauteilzustände in Dysisko (nach OPKI) | 126 |
| Abbildung 73: Ausschnitt der Inspektionsdaten Dysisko | 127 |
| Abbildung 74: Gesamtmenge der gruppierten Bauelemente, unterteilt nach Postleitzahlen (exemplarische Darstellung) | 132 |
| Abbildung 75: Verhältnis im finalen Daten zwischen natürlichen und synthetischen Daten | 134 |
| Abbildung 76: Ausschnitt der One-Hot kodierten Kostengruppen | 138 |
| Abbildung 77: Beispiel für eine (mäßige) linksschiefe Datenverteilung | 141 |
| Abbildung 78: Beispiel für eine (mäßige) rechtsschiefe Datenverteilung..... | 141 |
| Abbildung 79: Heatmap der Pearson-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3310 | 148 |
| Abbildung 80: Heatmap der Kendall-Korrelationskoeffizienten-Matrix für das Bauelement (KG) 3310 | 148 |
| Abbildung 81: Prozessdarstellung (BPMN) für das theoretische Modell des Prototyps | 151 |
| Abbildung 82: Illustration der Zerfallsrate zu verschiedenen Zeitpunkten des nicht linearen Abbaus des Abnutzungsvorrates eines Bauelementes | 154 |

| | |
|--|-----|
| Abbildung 83: Prozessablaufdiagramm Erstellen des neuronalen Modelles (Teil 1) | 157 |
| Abbildung 84: Prozessablaufdiagramm Erstellen des neuronalen Modelles (Teil 2) | 157 |
| Abbildung 85: Ausschnitte Panas DataFrame | 158 |
| Abbildung 86: Architektur des neuronalen Netzwerkes | 159 |
| Abbildung 87: Ergebnis KerasTuner | 162 |
| Abbildung 88: Lernkurve des neuronalen Modelles (MAPE) | 163 |
| Abbildung 89: Plot „Vorhersagen des Modells (Zerfallsrate) vs. Tatsächliche Werte (Zerfallsrate)“ | 164 |
| Abbildung 90: Screenshot Benutzeroberfläche Prototyp (Prognose über Standort) | 165 |
| Abbildung 91: Screenshot Benutzeroberfläche Prototyp (Prognose über Einflussfaktoren) | 165 |
| Abbildung 92: Prozessablaufdiagramm Restlebensdauer prognostizieren im Prototyp (Teil 1) | 166 |
| Abbildung 93: Prozessablaufdiagramm Restlebensdauer prognostizieren im Prototyp (Teil 2) | 166 |
| Abbildung 94: Prozessablaufdiagramm Restlebensdauer prognostizieren im Prototyp (Teil 3) | 166 |
| Abbildung 95: Dropdown Kostengruppen (Prototyp) | 167 |
| Abbildung 96: Inputs Alter und Baujahr (Prototyp) | 167 |
| Abbildung 97: Prognose über Einflussfaktoren: Eingabe der äußeren Umwelteinflüsse (Prototyp) | 168 |
| Abbildung 98: Prognose über Standort: Eingabe der Postleitzahl (Prototyp) | 168 |
| Abbildung 99: Darstellung der Zerfallsrate und des Abnutzungsvorrates (Prototyp) | 169 |
| Abbildung 100: Verlauf der Kurve des Abnutzungsvorrates einer tragenden Außenwand (Baujahr 1973, 1985, 2000) | 173 |
| Abbildung 101: a-Szenario für die KG 3310 | 177 |
| Abbildung 102: b-Szenario für die KG 3310 | 177 |
| Abbildung 103: c-Szenario für die KG 3310 | 178 |
| Abbildung 104: a-Szenario für die KG 3341 | 178 |
| Abbildung 105: b-Szenario für die KG 3341 | 179 |
| Abbildung 106: c-Szenario für die KG 3341 | 179 |
| Abbildung 107: a-Szenario für die KG 3342 | 180 |
| Abbildung 108: b-Szenario für die KG 3342 | 180 |
| Abbildung 109: c-Szenario für die KG 3342 | 181 |
| Abbildung 110: a-Szenario für die KG 3351 | 181 |

| | |
|--|-----|
| Abbildung 111: b-Szenario für die KG 3351 | 182 |
| Abbildung 112: c-Szenario für die KG 3351 | 182 |
| Abbildung 113: a-Szenario für die KG 3370 | 183 |
| Abbildung 114: b-Szenario für die KG 3370 | 183 |
| Abbildung 115: c-Szenario für die KG 3370 | 184 |
| Abbildung 116: a-Szenario für die KG 3620 | 184 |
| Abbildung 117: b-Szenario für die KG 3620 | 185 |
| Abbildung 118: c-Szenario für die KG 3620 | 185 |
| Abbildung 119: a-Szenario für die KG 3631 | 186 |
| Abbildung 120: b-Szenario für die KG 3631 | 186 |
| Abbildung 121: c-Szenario für die KG 3631 | 187 |
| Abbildung 122: a-Szenario für die KG 3632 | 187 |
| Abbildung 123: b-Szenario für die KG 3632 | 188 |
| Abbildung 124: c-Szenario für die KG 3632 | 188 |
| Abbildung 125: a-Szenario für die KG 3633 | 189 |
| Abbildung 126: b-Szenario für die KG 3633 | 189 |
| Abbildung 127: c-Szenario für die KG 3633 | 190 |
| Abbildung 128: a-Szenario für die KG 3634 | 190 |
| Abbildung 129: b-Szenario für die KG 3634 | 191 |
| Abbildung 130: c-Szenario für die KG 3634 | 191 |
| Abbildung 131: Standortspezifischer Verlauf des Abbaus des Abnutzungsvorrates der tragenden Außenwände (Betonfertigbauteile/Ortbeton) für die vier Standorte | 193 |
| Abbildung 132: Standortspezifischer Verlauf des Abbaus des Abnutzungsvorrates der Außentüren (Holz) für die vier Standorte | 194 |
| Abbildung 133: Vergleich der prognostizierten Lebensdauer für Außenwände (Beton) mit Referenzlebensdauer aus der Literatur | 195 |
| Abbildung 134: Abweichung des Jahresmittels der Lufttemperatur für Deutschland vom vieljährigen Mittel 1961-1990 für den Zeitraum 1881-2021 | 197 |

15 Tabellenverzeichnis

| | |
|--|-----|
| Tabelle 1: Beispiel für eine Zuordnung zwischen Feature und Label (Computer Vision)..... | 53 |
| Tabelle 2: Beispiel für die Zuordnung zwischen Features und einem Label (Regression)..... | 53 |
| Tabelle 3: Übliche Methoden der Aktivierung nach Sonnet..... | 60 |
| Tabelle 4: Aktuelle Lebensdauerdaten in der Literatur, Stand 02/2023..... | 77 |
| Tabelle 5: Faktoren der ISO 15686 - Teil 8..... | 80 |
| Tabelle 6: Erläuterungen der zu berücksichtigenden Faktoren nach der ISO 15686 - Teil 8..... | 82 |
| Tabelle 7: Technische Lebensdauer mit Einflussgrenzwerten von Fenstern nach Ritter..... | 84 |
| Tabelle 8: Erste Ebene der Kostengliederung nach DIN 276..... | 86 |
| Tabelle 9: Zweite Ebene der Kostengliederung am Beispiel der KG 300 nach DIN 276..... | 87 |
| Tabelle 10: Ausschnitt der dritten Ebene der Kostengliederung am Beispiel der KG 330 nach DIN 276..... | 87 |
| Tabelle 11: Kostengliederung mit vier Ebenen..... | 89 |
| Tabelle 12: Definitionen der klimatologischen Begriffe des Deutschen Wetterdienstes..... | 96 |
| Tabelle 13: Immaterielle Einflussfaktoren..... | 112 |
| Tabelle 14: Relevante Bauelemente..... | 113 |
| Tabelle 15: Vergleichbarkeit der Datensätze..... | 114 |
| Tabelle 16: Zusammenfassung Lufttemperatur, Niederschlag und Sonnenscheindauer..... | 122 |
| Tabelle 17: Zusammenfassung Windlastzone, Schneelastzone und Erschütterung..... | 123 |
| Tabelle 18: Zusammenfassung Hagelzone und Frosttage..... | 123 |
| Tabelle 19: Vergleich der Klassifizierungen nach Krug und OPKI..... | 127 |
| Tabelle 20: Struktur der Basisdaten (exemplarische Darstellung)..... | 128 |
| Tabelle 21: Basisdaten (exemplarische Darstellung)..... | 129 |
| Tabelle 22: Basisdaten gruppiert nach Bauelementen (exemplarische Darstellung)..... | 129 |
| Tabelle 23: Gruppierte Bauelemente, unterteilt nach Postleitzahlen (exemplarische Darstellung)..... | 130 |
| Tabelle 24: Gruppierte Bauelemente, unterteilt nach Postleitzahlen (exemplarische Darstellung)..... | 131 |
| Tabelle 25: Standortabhängige Umweltbedingungen..... | 136 |
| Tabelle 26: Gruppierte Bauelemente, unterteilt nach Postleitzahlen - ohne Umweltbedingungen (exemplarische Darstellung)..... | 136 |
| Tabelle 27: Gruppierte Bauelemente, unterteilt nach Postleitzahlen - mit Umweltbedingungen (exemplarische Darstellung)..... | 136 |

| | |
|---|-----|
| Tabelle 28: Datensatz - Zusammenführung aller Bauelemente (exemplarische Darstellung) | 137 |
| Tabelle 29: Datensatz – One-Hot kodiert (exemplarische Darstellung)..... | 138 |
| Tabelle 30: Aufbau des Datensatzes nach Ergänzung durch synthetische Daten..... | 142 |
| Tabelle 31: Schiefe der Parameter im zusammengesetzten Datensatz (SPSS) | 143 |
| Tabelle 32: Kurtosis der Parameter im zusammengesetzten Datensatz (SPSS) | 144 |
| Tabelle 33: Skalenniveaus der verwendeten Parameter..... | 145 |
| Tabelle 34: Interpretation des Korrelationskoeffizienten r nach Cohen | 147 |
| Tabelle 35: Ermittlung der Zerfallsrate über Nutzereingabe und die assoziierten Einflussfaktoren am Standort..... | 152 |
| Tabelle 36: Features und Label für das neuronale Modell | 156 |
| Tabelle 37: Wertebereiche und Mittelwerte der Trainingsdaten | 172 |
| Tabelle 38: positive bivariate Szenarien (a-Szenarien)..... | 174 |
| Tabelle 39: negative bivariate Szenarien (b-Szenarien)..... | 175 |
| Tabelle 40: multivariate Szenarien (c-Szenarien) | 176 |

16 Literatur

References

1. Rotermund U, editor. fm.benchmarking Bericht 2021: Sonderthema: Ausschreibung von TGM-Leistungen. 1st ed. Höxter: rotermund.ingenieure; 2021.
2. Arlt J, Pfeiffer M. Lebensdauer der Baustoffe und Bauteile zur Harmonisierung der wirtschaftlichen Nutzungsdauer im Wohnungsbau: Forschungsbericht F 815 Juni 2004. Hannover; 06-2004.
3. DIN 18960:2020-11, Nutzungskosten im Hochbau. Berlin: Beuth Verlag GmbH. doi:10.31030/3188176.
4. DIN 31051:2019-06, Grundlagen der Instandhaltung. Berlin: Beuth Verlag GmbH. doi:10.31030/3048531.
5. DIN EN 13306:2018-02, Instandhaltung_- Begriffe der Instandhaltung; Dreisprachige Fassung EN_13306:2017. Berlin: Beuth Verlag GmbH. doi:10.31030/2641990.
6. Schröder J. Zustandsbewertung grosser Gebäudebestände. Schweizer Ingenieur und Architekt. 1989:449–59. doi:10.5169/seals-77093.
7. Frank Ritter. Lebensdauer von Bauteilen und Bauelementen: Modellierung und praxisnahe Prognose [Dissertation]. Darmstadt: Technische Universität Darmstadt; 26.01.2011.
8. Ulrich Agethen, Karl-Joachim Frahm, Konrad Renz, Erik Peter Thees. Lebensdauer von Bauteilen, Zeitwerte (1. Auflage). 1st ed.; 14.03.2008.
9. Deutsche Energie-Agentur GmbH (dena). Energieeffizienz in der Kommune. 2022. <https://www.dena.de/themen-projekte/energieeffizienz/oeffentliche-hand/>. Accessed 4 Dec 2022.
10. Reichenbach H, Link G, Kamlah A, editors. Gesammelte Werke in 9 Bänden, Band 7, Wahrscheinlichkeitslehre. 2nd ed. Braunschweig: Vieweg; 1994.
11. Dr.-Ing. Carolin Bahr, Prof. Dr.-Ing. Kunibert Lennerts. Lebens- und Nutzungsdauer von Bauteilen: Aktenzeichen: 10.08.17.7-08.20; 26.02.2010.
12. Ulrich Agethen, Karl-Joachim Frahm, Kurt Neumann-Klößner, Elmar Klein, Konrad Renz, Erik Peter Thees. Zeitwertermittlung und Lebensdauer von Bauteilen (2. Auflage): Kriterien, Methoden, Verfahren, Lebensdauerkatalog von Bauteilen. Berechnungsmethoden zur sachgerechten Ermittlung insbesondere des technischen Zeitwertes. 2nd ed.; 08.2019.
13. Hauseigentümergeverband Schweiz (HEV), Schweizerischen Mieterinnen- und Mieterverband (MV). Lebensdauertabelle. 7th ed.; 2010.
14. Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Bundesamt für Bauwesen und Raumordnung (BBSR). Nutzungsdauern von Bauteilen - Informationsportal Nachhaltiges Bauen. 14.01.2023. <https://www.nachhaltigesbauen.de/austausch/nutzungsdauern-von-bauteilen/>. Accessed 14 Jan 2023.

15. Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Bundesamt für Bauwesen und Raumordnung (BBSR). Nutzungsdauerangaben von ausgewählten Bauteilen der Kostengruppen 300, 400 und 500 nach DIN 276-1: Entwurf der BBSR-Endfassung vom 20.10.2009. Berlin; 20.10.2009.
16. Bogenstätter U. Technische Lebensdauern: Synopse. Nürtingen-Geislingen; 2007.
17. Institut für Erhaltung und Modernisierung von Bauwerken e.V. (IEMB). Lebensdauer von Bauteilen und Bauteilschichten (Info-Blatt Nr. 4.2): Tragkonstruktion, Nichttragende Konstruktion, Installationen und betriebstechnische Anlagen, Außenanlagen. Berlin; 2006.
18. Maximilian Ferdinand Reiser. Bestimmung der Herstellungskosten und Instandsetzungskosten sowie der Grauen Energie für die Gesamtnutzungsdauer unterschiedlicher Immobilientypen unter besonderer Berücksichtigung der Lebensdauer der Bauteile. München: TECHNISCHE UNIVERSITÄT MÜNCHEN.
19. Thomas Häßel, Daniel Walter, Ingo Besenbruch. Operationalisierung mittels künstlicher Intelligenz bei Gebäuden (OPKI): F&E Vorhaben: P1-SZ2-6 - (InnoTop) Aktenzeichen: 84005347-1951. 1st ed. Kaiserslautern; 2022.
20. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics. 1943;5:115–33. doi:10.1007/bf02478259.
21. J. McCarthy. A PROPOSAL FOR THE DARTMOUTH SUMMER RESEARCH PROJECT ON ARTIFICIAL INTELLIGENCE. 1955. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>. Accessed 29 Nov 2022.
22. Bughin J, Seong J, Manyika J, Chui M, Joshi R. Notes from the AI frontier: Modeling the impact of AI on the world economy – McKinsey (Sept 2018). Report: DISCUSSION PAPER SEPTEMBER 2018. 2018.
23. Wolfgang Wahlster, Christoph Winterhalter. Deutsche Normungsroadmap Künstliche Intelligenz - Ausgabe 2: Fortschreibung der wegweisenden Ergebnisse und Handlungsempfehlungen der ersten Ausgabe; 12.2022.
24. Kiela D, Bartolo M, Nie Y, Kaushik D, Geiger A, Wu Z, et al. Dynabench: Rethinking Benchmarking in NLP. In: Toutanova K, Rumshisky A, Zettlemoyer L, Hakkani-Tur D, Beltagy I, Bethard S, et al., editors. Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies; Online. Stroudsburg, PA, USA: Association for Computational Linguistics; 2021. p. 4110–4124. doi:10.18653/v1/2021.naacl-main.324.
25. Dipl.-Ing. Thomas Häßel, Ingo Besenbruch cB, Prof. Dr.-Ing. Karsten Körkemeyer, Jahanzeb Khan B, Dr. Max Langbein. Instandhaltungsmanagement für Immobilien als nachhaltiges Element des Facility Managements [FM^EM]: Zusammenstellung der Projektresultate in Form eines Anwenderleitfadens [Abschlussbericht]. Kaiserslautern: Technische Universität Kaiserslautern; 03.2014.
26. Dipl.-Ing. Thomas Häßel, cand. ing. Florian Wendel, Frank Busch, cand. B.Sc., Prof. Dr.-Ing. Karsten Körkemeyer. Instandhaltungsmanagement für Immobilien als nachhaltiges Element des Facility Managements [FM^EM 2]: Überführung der Methode > dysisko < in

- einer Softwareversion mit praxisbezogenem Anwendungstest [Abschlussbericht]. Kaiserslautern: Technische Universität Kaiserslautern; 03.2017.
27. Backhaus N, Steinemann M. Leitfaden für wissenschaftliches Arbeiten. 6th ed. Zürich: Geographisches Inst. Abt. Anthropogeographie Univ. Zürich; 2002.
 28. DIN 32736:2000-08, Gebäudemanagement_ - Begriffe und Leistungen. Berlin: Beuth Verlag GmbH. doi:10.31030/8980603.
 29. Weiland C. Instandhaltung oder Instandsetzung - fm-benchmarking.de. 2017. <https://www.fm-benchmarking.de/instandhaltung-oder-instandsetzung/>. Accessed 11 Dec 2022.
 30. Bahr C. Realdatenanalyse zum Instandhaltungsaufwand öffentlicher Hochbauten: Ein Beitrag zur Budgetierung. Karlsruhe: Univ.-Verl. Karlsruhe; 2008.
 31. Bateman JF. Preventive maintenance: Stand alone manufacturing compared with cellular manufacturing. INDUSTRIAL MANAGEMENT-CHICAGO THEN ATLANTA-. 1995;37:19.
 32. King M. Optimierungsstrategien Im Nutzungszyklus Von Immobilien: Handlungsempfehlungen Für Erfolgreiche Sanierungen. Wiesbaden: Gabler; 2019.
 33. Swanson L. Linking maintenance strategies to performance. International Journal of Production Economics. 2001;70:237–44. doi:10.1016/S0925-5273(00)00067-0.
 34. Schröder W. Ganzheitliches Instandhaltungsmanagement: Aufbau, Ausgestaltung und Bewertung. 1st ed. Wiesbaden: Gabler; 2010.
 35. Biedermann H. Anlagenmanagement: Managementinstrumente zur Wertsteigerung. 2nd ed. Köln: TÜV Media; 2008.
 36. Dipl.-Ing. Thomas Häßel. Instandhaltungsmanagement I. Kaiserslautern; 2022.
 37. Jörg Klingenberg. Ein Beitrag zur systematischen Instandhaltung von Gebäuden [Dissertation]. Darmstadt: Technische Universität Darmstadt; 2007.
 38. DIN 276:2018-12, Kosten im Bauwesen. Berlin: Beuth Verlag GmbH. doi:10.31030/2873248.
 39. Isabella Christine Altmann. Einfluss von Veralterungsprozessen auf den Wert von Immobilien [Dissertation]. München: TECHNISCHE UNIVERSITÄT MÜNCHEN; 2016.
 40. Lück W, editor. Lexikon der Betriebswirtschaft. 4th ed. Landsberg am Lech: Verl. Moderne Industrie; 1990.
 41. Meyering S. Existenzgründung durch Einzelunternehmenskauf: Bewertung, Kaufpreiszahlung, Ertragsteuern. Berlin: E. Schmidt; 2007.
 42. DIN EN 60300-3-3:2005-03, Zuverlässigkeitsmanagement_ - Teil_3-3: Anwendungsleitfaden_ - Lebenszykluskosten (IEC_60300-3-3:2004); Deutsche Fassung EN_60300-3-3:2004. Berlin: Beuth Verlag GmbH. doi:10.31030/9608069.
 43. DIN EN 15804:2022-03, Nachhaltigkeit von Bauwerken_ - Umweltproduktdeklarationen_ - Grundregeln für die Produktkategorie Bauprodukte; Deutsche Fassung EN_15804:2012+A2:2019_+ AC:2021. Berlin: Beuth Verlag GmbH. doi:10.31030/3294005.

44. Lützkendorf T, editor. Nachhaltigkeit in der Wohnungswirtschaft - Ein Überblick: Tagung 'Nachhaltigkeit von Investitionsentscheidungen in der Immobilien- und Wohnungswirtschaft', Düsseldorf, 8. November 2007; 2007.
45. Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Bundesamt für Bauwesen und Raumordnung (BBR). Leitfaden Nachhaltiges Bauen: Zukunftsfähiges Planen, Bauen und Betreiben von Gebäuden. 3rd ed. Berlin; 2019.
46. Reparatur – Wikipedia. 12.02.2024. <https://de.wikipedia.org/wiki/Reparatur>. Accessed 12 Feb 2024.
47. DIN Deutsches Institut für Normung e. V. DIN EN ISO 9000:2015-11, Qualitätsmanagementsysteme_ - Grundlagen und Begriffe (ISO_9000:2015); Deutsche und Englische Fassung EN_ISO_9000:2015. Berlin: Beuth Verlag GmbH. doi:10.31030/2325650.
48. Schönfelder UT. Zustandsermittlung von Immobilien mittels Verfahren ERAB: Grundlagen für Instandhaltungsstrategien. Köln: Werner; 2012.
49. Rotermund U, editor. Fm.benchmarking Bericht 2017: Vergleichen Sie Ihre Immobilien-Kennzahlen. 1st ed. Höxter: rotermund.ingenieure; 2017.
50. German Facility Management Association. GEFMA 100-1:2004-07: Facility Management - Grundlagen 2004-07;03.080.10. Berlin: Beuth Verlag GmbH.
51. Tomm A, Rentmeister O, Finke H. Geplante Instandhaltung: Ein Verfahren zur systematischen Instandhaltung von Gebäuden. Aachen: LBB; 1995.
52. ISO - International Organization for Standardization. ISO 15686-6:2004: Buildings and constructed assets — Service life planning — Part 6: Procedures for considering environmental impacts 09.2004;91.040.01.
53. ISO - International Organization for Standardization. ISO 15686-8:2008: Buildings and constructed assets — Service-life planning — Part 8: Reference service life and service-life estimation 06.2008.
54. Krug K-E. Wirtschaftliche Instandhaltung von Wohngebäuden durch methodische Inspektion und Instandsetzungsplanung [Dissertation]: Technische Universität Braunschweig; 1985.
55. Zarkov H, editor. IP BAU - Alterungsverhalten von Bauteilen und Unterhaltskosten: Grundlagendaten für den Unterhalt und die Erneuerung von Wohnbauten. Bern: Eidg. Dr.-Sachen- und Materialzentrale; 1994.
56. Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen. Nutzungsdauern von Bauteilen. <https://www.nachhaltigesbauen.de/austausch/nutzungsdauern-von-bauteilen/>. Accessed 14 Nov 2023.
57. Ertel W. Grundkurs Künstliche Intelligenz. Wiesbaden: Springer Fachmedien Wiesbaden; 2021.
58. European Commission, Directorate-General for Communications Networks, Content and Technology. Koordinierter Plan für künstliche Intelligenz: Document 52018DC0795. Brussels; 07.12.2008.

-
59. Russell SJ, Norvig P. Artificial intelligence: A modern approach. Hoboken, NJ: Pearson; 2021.
 60. ISO - International Organization for Standardization. ISO/IEC 22989:2022-07: Information technology - Artificial intelligence - Artificial intelligence concepts and terminology 2022-07;01.040.35, 35.020.
 61. Multiagent systems: A modern approach to distributed artificial intelligence. Cambridge, Massachusetts: MIT Press; 1999.
 62. Breiman L. Statistical Modeling: The Two Cultures (with comments and a rejoinder by the author). *Statist. Sci.* 2001. doi:10.1214/ss/1009213726.
 63. James G, Witten D, Hastie T, Tibshirani R. An Introduction to Statistical Learning. New York, NY: Springer New York; 2013.
 64. Langley P. The changing science of machine learning. *Mach Learn.* 2011;82:275–9. doi:10.1007/s10994-011-5242-y.
 65. Alpaydm E. Introduction to machine learning. 2nd ed. Cambridge, Massachusetts: MIT Press; 2010.
 66. Bishop CM. Pattern recognition and machine learning. New York, NY: Springer; 2006.
 67. Mohri M, Rostamizadeh A, Talwalkar A. Foundations of machine learning. Cambridge, Mass., London: The MIT Press; 2012.
 68. Alfonso R. Reyes. Why Machine Learning is not Artificial Intelligence? *Medium.* 18.12.2020.
 69. Nilsson NJ. The quest for artificial intelligence: Cambridge University Press; 2009.
 70. Lu H, Li Y, Chen M, Kim H, Serikawa S. Brain Intelligence: Go beyond Artificial Intelligence. *Mobile Netw Appl.* 2018;23:368–75. doi:10.1007/s11036-017-0932-8.
 71. Weber F. Künstliche Intelligenz für Business Analytics. Wiesbaden: Springer Fachmedien Wiesbaden; 2020.
 72. Aha DW, editor. *Lazy Learning.* Dordrecht: Springer; 1997.
 73. Atkeson CG, Moore AW, Schaal S. Locally Weighted Learning. *Artificial Intelligence Review.* 1997;11:11–73. doi:10.1023/A:1006559212014.
 74. *Lazy learning.* Dordrecht: Kluwer Acad. Publ; 1997.
 75. Yinyu Ye. Zero-Order and First-Order Optimization Algorithms I. Stanford, CA 94305, U.S.A.
 76. Frankfurter Allgemeine Zeitung. OpenAI: Nutzerzahlen von KI-Software ChatGPT gesunken. *Frankfurter Allgemeine Zeitung.* 08.09.2023.
 77. OpenAI. GPT-4 is OpenAI's most advanced system, producing safer and more useful responses. 2023. <https://openai.com/gpt-4>. Accessed 13 Nov 2023.
 78. Prof. Dr. Oliver Bendel. Definition: Generative KI. Springer Fachmedien Wiesbaden GmbH. 14.03.2023.

79. Hecker D, Döbel I, Petersen U, Rauschert A, Schmitz V, Voß A. Zukunftsmarkt Künstliche Intelligenz. Potenziale und Anwendungen: Fraunhofer-Gesellschaft; 2017.
80. ISO - International Organization for Standardization. ISO/IEC 23053:2022-06: Framework for Artificial Intelligence (AI) Systems Using Machine Learning (ML) 2022-06;35.020.
81. Paaß G, Hecker D. Künstliche Intelligenz. Wiesbaden: Springer Fachmedien Wiesbaden; 2020.
82. RICHARD BELLMAN. A Markovian Decision Process. Journal of Mathematics and Mechanics. 1957;6:679–84.
83. Joseph Santarcangelo. IBM Datenanalyse mit Python | Coursera: Analyzing data with Python is an essential skill for Data Scientists and Data Analysts. 23.01.2023. <https://www.coursera.org/learn/data-analysis-with-python>. Accessed 23 Jan 2023.
84. Alexis Cook. Scaling and Normalization. Kaggle. 14.12.2021.
85. Pragati Baheti. Train Test Validation Split: How To & Best Practices [2022]. 2022. <https://www.v7labs.com/blog/train-validation-test-set#h2>. Accessed 18 Dec 2022.
86. Husar P. Elektrische Biosignale in der Medizintechnik. Berlin, Heidelberg: Springer Berlin Heidelberg; 2020.
87. Silbernagl S, Despopoulos A. Taschenatlas der Physiologie. 5th ed. Stuttgart, New York: Thieme; 2001.
88. Prof. Dr. Reinhard Jahn. Wie Nervenzellen miteinander reden. 2016. <https://www.mpg.de/synapse>. Accessed 10 Feb 2024.
89. Marvin Lee Minsky. Theory of neural-analog reinforcement systems and its application to the brain-model problem [Dissertation]: Princeton University; 1954.
90. ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychol Rev. 1958;65:386–408. doi:10.1037/h0042519.
91. Sebastian Otte. Das Perzeptron: Künstliche neuronale Netze. 2009. <https://www.cs.hs-rm.de/~panitz/prog3WS08/perceptron.pdf>. Accessed 31 Jan 2023.
92. Heistermann J. Genetische Algorithmen: Theorie und Praxis evolutionärer Optimierung. Wiesbaden, s.l.: Vieweg+Teubner Verlag; 1994.
93. Görz G, Rollinger C-R, Schneeberger J, editors. Handbuch der künstlichen Intelligenz. 3rd ed. München, Wien: Oldenbourg Verlag; 2000.
94. Zell A. Simulation neuronaler Netze. 2nd ed. München, Wiesbaden: Oldenbourg; 1997.
95. Rumelhart DE, editor. Parallel distributed processing. 12th ed. Cambridge, Mass.: MIT Pr; 1999.
96. Braun H. Neuronale Netze: Optimierung durch Lernen und Evolution. Berlin, Heidelberg: Springer Berlin Heidelberg; 1997.
97. Sonnet D. Neuronale Netze kompakt: Vom Perzeptron zum Deep Learning. Wiesbaden, Heidelberg: Springer Vieweg; 2022.

98. Wikipedia. Künstliches Neuron. 2022. https://de.wikipedia.org/w/index.php?title=Künstliches_Neuron&oldid=226148356. Accessed 11 Feb 2023.
99. Crone SF. Neuronale Netze zur Prognose und Disposition im Handel. 1st ed. Wiesbaden: Gabler; 2010.
100. Jacob H, Hansmann K-W, Layer M, Preßmar DB, Alex B. Künstliche neuronale Netze in Management-Informationssystemen. Wiesbaden: Gabler Verlag; 1998.
101. Schumann M, Lohrbach T, Retzko R. Einführung in Aufbau und Arbeitsweise künstlicher neuronaler Netze: Georg-August-Univ., Abt. Wirtschaftsinformatik II; 1991.
102. Helga Förster. Erstellung von digitalen Bodenprognosekarten mit Künstlichen Neuronalen Netzen am Beispiel des Pfälzer Waldes und des Mittleren Saaletals. Jena: Friedrich-Schiller-Universität; 08.2004.
103. Nauck D, Klawonn F, Kruse R. Neuronale Netze und Fuzzy-Systeme. Wiesbaden: Vieweg+Teubner Verlag; 1994.
104. Strecker S. Künstliche Neuronale Netze : Aufbau und Funktionsweise 2004. Gießen: Universitätsbibliothek.
105. Keysers C, Gazzola V. Hebbian learning and predictive mirror neurons for actions, sensations and emotions. *Philos Trans R Soc Lond B Biol Sci*. 2014;369:20130175. doi:10.1098/rstb.2013.0175.
106. Rao VB, Rao V, Rao HV. C++ neural networks and fuzzy logic. 2nd ed. New York: MIS-Press; 1995.
107. Aizenberg IN, Aizenberg NN, Vandewalle J. Multi-Valued and Universal Binary Neurons. Boston, MA: Springer US; 2000.
108. LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, Jackel LD. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*. 1989;1:541–51. doi:10.1162/neco.1989.1.4.541.
109. scikit-learn. Webseite - Dokumentation scikit-learn - API Reference. 27.07.2023. <https://scikit-learn.org/stable/modules/classes.html#module-sklearn.metrics>. Accessed 28 Jul 2023.
110. James Bergstra, Daniel Yamins, David Cox. Making a Science of Model Search: Hyperparameter Optimization in Hundreds of Dimensions for Vision Architectures. In: Sanjoy Dasgupta, David McAllester, editors; 2013/02/13: PMLR; 2013/02/13. p. 115–123.
111. O'Malley T, Bursztein E, Long J, Chollet F, Jin H, Invernizzi L, others. KerasTuner 2019.
112. Akiba T, Sano S, Yanase T, Ohta T, Koyama M. Optuna: A Next-generation Hyperparameter Optimization Framework; 25.07.2019.
113. Team K. Keras: Deep Learning for humans. 02.08.2023. https://keras.io/keras_core/announcement/. Accessed 5 Aug 2023.
114. Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z, Citro C, et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems; 14.03.2016.

115. Ministerium des Innern des Landes Nordrhein-Westfalen, Referat 14. HSMBI Inhalt : Historisch: Landesinstitut für Bauwesen des Landes Nordrhein-Westfalen Bek. d. Ministeriums für Bauen und Wohnen des Landes Nordrhein-Westfalen v. 9. 11. 1995-1 C 3-010I 1) | RECHT.NRW.DE. 12.03.2023. https://recht.nrw.de/lmi/owa/br_bes_text?anw_nr=1&gld_nr=&ugl_nr=2005&bes_id=110&val=110&ver=7&sg=0&aufgehoben=J&menu=1. Accessed 12 Mar 2023.
116. SIRADOS. Elementemethode. 11.02.2024. <https://www.sirados.de/blog/elementemethode>. Accessed 11 Feb 2024.
117. Deutscher Wetterdienst. Wetter und Klima - Deutscher Wetterdienst - Glossar. 05.04.2023. https://www.dwd.de/DE/service/lexikon/lexikon_node.html. Accessed 5 Apr 2023.
118. Mehra S-R. Stadtbauphysik: Grundlagen klima- und umweltgerechter Städte. Wiesbaden: Springer Vieweg; 2021.
119. Hupfer P, Kuttler W, Chmielewski F-M, Heyer E, editors. Witterung und Klima: Eine Einführung in die Meteorologie und Klimatologie. 12th ed. Stuttgart: Teubner; 2006.
120. Weidlich B, Breustedt W, et al. Rationelle Energieverwendung im Planungsgebiet Erlangen-West. Köln; 1976.
121. Dr. Jost A. Studer. Erschütterungseinwirkungen auf Bauwerke. CH-8038 Zürich.
122. DIN Deutsches Institut für Normung e. V. DIN 4150-3:2016-12: Erschütterungen im Bauwesen_ - Teil_3: Einwirkungen auf bauliche Anlagen. Berlin: Beuth Verlag GmbH. doi:10.31030/2579353.
123. Richart FE, Woods RD, Hall JR. Vibrations of soils and foundations. Englewood Cliffs, NJ: Prentice-Hall; 1970.
124. DIN Deutsches Institut für Normung e. V. DIN EN 1998-1/NA:2021-07: Nationaler Anhang_ - National festgelegte Parameter_ - Eurocode_8: Auslegung von Bauwerken gegen Erdbeben_ - Teil_1: Grundlagen. Berlin: Beuth Verlag GmbH. doi:10.31030/3262205.
125. DIN Deutsches Institut für Normung e. V. DIN 4149:2005-04: Bauten in deutschen Erdbebengebieten - Lastannahmen, Bemessung und Ausführung üblicher Hochbauten. Berlin: Beuth Verlag GmbH.
126. DIN Deutsches Institut für Normung e. V. DIN EN 1998-1/NA:2011-01: Nationaler Anhang_ - National festgelegte Parameter_ - Eurocode_8: Auslegung von Bauwerken gegen Erdbeben_ - Teil_1: Grundlagen, Erdbebeneinwirkungen und Regeln für Hochbau. Berlin: Beuth Verlag GmbH. doi:10.31030/1738038.
127. Schwarz J. Festlegung effektiver Beschleunigungen für probabilistische Gefährdungszonen im Zusammenhang mit der nationalen Anwendung des EC 8: Forschungsbericht. Stuttgart: Fraunhofer-IRB-Verl.; 1998.
128. DIN Deutsches Institut für Normung e. V. DIN EN 1998-1/NA:2018-10 (Entwurf): Nationaler Anhang_ - National festgelegte Parameter_ - Eurocode_8: Auslegung von Bauwerken gegen Erdbeben_ - Teil_1: Grundlagen, Erdbebeneinwirkungen und Regeln für Hochbau. Berlin: Beuth Verlag GmbH. doi:10.31030/2885780.

129. Dr. Diethelm Kaiser, Dr. Thomas Spies. Anwendung des Ausschlusskriteriums Seismische Aktivität: Standortwahl, Ausschlusskriterien, Anwendung des Ausschlusskriterium Seismische Aktivitäten. Hannover; 29.04.2020.
130. Dlubal Software GmbH. Geo-Zonen-Tool für Lastermittlung. 16.08.2022. <https://www.dlubal.com/de/schnee-wind-erdbeben-lastzonen/erdbeben-din-en-1998-1.html#¢er=51.32374658474385,10.458984375000002&marker=52.520007,13.404954>. Accessed 6 Apr 2023.
131. Groos JC, Fritschen R, Ritter JRR. Untersuchung induzierter Erdbeben hinsichtlich ihrer Spürbarkeit und eventueller Schadenswirkung anhand DIN 4150 [Analysis of induced e-arthquakes regarding their perceptibility and potential damaging effects based on DIN 4150] 2013. doi:10.5445/IR/1000038446.
132. DIN Deutsches Institut für Normung e. V. DIN 4108-3:2018-10: Wärmeschutz und Energie-Einsparung in Gebäuden_- Teil_3: Klimabedingter Feuchteschutz_- Anforderungen, Berechnungsverfahren und Hinweise für Planung und Ausführung. Berlin: Beuth Verlag GmbH. doi:10.31030/2873064.
133. Dipl.-Met. Jens Hoffmann. Wetter und Klima - Deutscher Wetterdienst - Thema des Tages - Hagelmessung - Wirklichkeit oder Utopie? 2019. https://www.dwd.de/DE/wetter/thema_des_tages/2019/7/9.html. Accessed 7 Apr 2023.
134. Fritz Hatzfeld, Susanne Kurz. Klimaangepasstes Bauen - Kriteriensteckbrief „Widerstandsfähigkeit gegen Naturgefahren: Wind, Starkregen, Hagel, Schnee/feuchte Winter und Hochwasser“. Aachen; 2010.
135. Münchener Rückversicherungs-Gesellschaft. Globus der Naturgefahren. München; 2009.
136. Bayer Cropscience. Webpräsenz der Firma Bayer AG –Cropscience: Hagelschlagrisikokarte nach Schadensätzen, Monheim. 2011. (nicht mehr aufrufbar). Accessed 6 Apr 2023.
137. Umweltbundesamt. Luftdaten nach Stationen. 2023. <https://www.umweltbundesamt.de/daten/luft/luftdaten/stationen/eJzrXpScv9BwUXEykEh-JXGVkYGSsa2Csa2i6qCRzkaHxorZUBYuKS5YYmlgYLEI-JdCuCqzCwAPJD8pF1JCdOacNmnImugRnYOBOIUWaGi8oSDxCI1NQCqFSCK-KXmlkCllkQptTAAmboot4pzUW5y0-KcxJLTDp5-RWuuK5xYnJOXftpB7pL-TwcGRgCJqmyJ>. Accessed 7 Apr 2023.
138. DIN Deutsches Institut für Normung e. V. DIN EN 1991-1-3/NA:2019-04: Nationaler Anhang_- National festgelegte Parameter_- Eurocode_1: Einwirkungen auf Tragwerke_- Teil_1-3: Allgemeine Einwirkungen_- Schneelasten. Berlin: Beuth Verlag GmbH. doi:10.31030/3041194.
139. DIN Deutsches Institut für Normung e. V. DIN EN 1991-1-3:2023-03: Eurocode_1: Einwirkungen auf Tragwerke_- Teil_1-3: Allgemeine Einwirkungen_- Schneelasten; Deutsche und Englische Fassung prEN_1991-1-3:2023. Berlin: Beuth Verlag GmbH. doi:10.31030/3412918.

140. Deutschen Instituts für Bautechnik (DIBt). Zuordnung der Windlast- und Schneelastzonen nach Verwaltungsgrenzen. 2020. <https://www.dibt.de/de/aktuelles/meldungen/nachricht-detail/meldung/aktualisiert-zuordnung-der-windlast-und-schneelastzonen-nach-verwaltungsgrenzen>. Accessed 12 Apr 2023.
141. Ministerium für Wirtschaft, Bau und Tourismus. Liste der Technischen Baubestimmungen 2015: Bekanntmachung des Ministeriums für Wirtschaft, Bau und Tourismus.
142. Wichura B, Hoffmann K. Flächenhafte Analyse von Schneelastmesswerten in fünf Landkreisen und ihr Vergleich mit den Schneelastzonenendaten der DIN 1055-5:2005 als Pilotuntersuchung für die Überarbeitung der Schneelastzonenkarte: Amtliches Gutachten. Stuttgart: Fraunhofer IRB Verlag; 2017.
143. Harten U. Physik. Berlin, Heidelberg: Springer Berlin Heidelberg; 2021.
144. Kujawa W, Olewnik-Kruszkowska E, Nowaczyk J. Concrete Strengthening by Introducing Polymer-Based Additives into the Cement Matrix-A Mini Review. Materials (Basel) 2021. doi:10.3390/ma14206071.
145. KIM D-H. COMPOSITE STRUCTURES FOR CIVIL AND ARCHITECTURAL ENGINEERING. [S.I.]: CRC PRESS; 2019.
146. Annett Püschel, Wiebke Winzig, Manfred Theel. Entwicklung der Globalstrahlung 1983 - 2020 in Deutschland; 06.01.2023.
147. Deutscher Wetterdienst. Klimastatusbericht Deutschland 2019. Offenbach am Main; 2019.
148. DIN Deutsches Institut für Normung e. V. DIN EN 1991-1-4/NA:2023-02: Nationaler Anhang_- National festgelegte Parameter_- Eurocode_1: Einwirkungen auf Tragwerke_- Teil_1-4: Allgemeine Einwirkungen_- Windlasten. Berlin: Beuth Verlag GmbH. doi:10.31030/3401887.
149. DIN Deutsches Institut für Normung e. V. DIN EN 1991-1-4:2010-12: Eurocode_1: Einwirkungen auf Tragwerke_- Teil_1-4: Allgemeine Einwirkungen_- Windlasten; Deutsche Fassung EN_1991-1-4:2005_+ A1:2010_+ AC:2010. Berlin: Beuth Verlag GmbH. doi:10.31030/1625598.
150. Behörde für Justiz und Verbraucherschutz der Freien und Hansestadt Hamburg. Technische Baubestimmungen, die bei der Erfüllung der Grundanforderungen an Bauwerke zu beachten sind. In: AMTLICHER ANZEIGER: TEIL II DES HAMBURGISCHEN GESETZ- UND VERORDNUNGSBLATTES; 20.05.2022.
151. Kalusche W. Technische Lebensdauer von Bauteilen und wirtschaftliche Nutzungsdauer eines Gebäudes. In: Held H, Axhausen KW, editors. Bauen, Bewirtschaften, Erneuern: Gedanken zur Gestaltung der Infrastruktur ; [Festschrift zum 60. Geburtstag von Prof. Dr. Hans-Rudolf Schalcher ; Kolloquium zum Thema "Bauen, Bewirtschaften, Erneuern - Gedanken zur Gestaltung der Infrastruktur" am 9. Juli 2004 an der ETH Höggerberg. Zürich: vdf Hochschulverl. an der ETH Zürich; 2004.
152. Dipl.-Ing. Jörg Klingenberg. Ein Beitrag zur systematischen Instandhaltung von Gebäuden [Dissertation]. Darmstadt; 2007.
153. Schwaiger B. Strukturelle und dynamische Modellierung von Gebäudebeständen; 2003.

-
154. Google. Ausschnitt der Karte von Deutschland: Google; 2023.
155. Deutsche Wetterdienst. Vieljährige Mittelwerte des Deutschen Wetterdienstes: Mittelwerte über einen Zeitraum von 30 Jahren. https://www.dwd.de/DE/leistungen/klimadatendeutschland/vielj_mittelwerte.html. Accessed 16 Apr 2023.
156. Deutsches GeoForschungsZentrum GFZ. Plattform zur Abfrage von gefährdungskonsistenten Antwortspektren (UHS) für beliebige Punkte in Deutschland sowie von nationalen Erdbebengefährdungskarten nach dem Berechnungsmodell von Grünthal et al. (2018). 2023. <http://www-app5.gfz-potsdam.de>. Accessed 31 Jul 2023.
157. Deutscher Wetterdienst. Climate Data Center: Jahresraster der Anzahl der Frosttage. 2022. <https://cdc.dwd.de/portal/202209231028/mapview>. Accessed 8 May 2023.
158. Schmuller J. Statistik mit R für Dummies. 1st ed. Newark: John Wiley & Sons Incorporated; 2017.
159. Aggarwal CC. Outlier Analysis. 2nd ed. Cham: Springer; 2017.
160. DIN Deutsches Institut für Normung e. V. Entwurf DIN EN ISO/IEC 23053 (04/2023): Framework für Systeme der Künstlichen Intelligenz (KI) basierend auf maschinellem Lernen (ML) (ISO/IEC 23053:2022); Deutsche und Englische Fassung prEN ISO/IEC 23053:2023 03.03.2023;35.020.
161. S. S. Stevens. On the Theory of Scales of Measurement. *Science*. 1946;103:677–80.
162. Brownlee J. Ordinal and One-Hot Encodings for Categorical Data. *Machine Learning Mastery*. 11.06.2020.
163. Yadav D. Categorical encoding using Label-Encoding and One-Hot-Encoder. *Towards Data Science*. 06.12.2019.
164. Yule GU, Filon LNG. Karl Pearson. 1857-1936. *Obituary Notices of Fellows of the Royal Society*. 1936;2:73–110.
165. Dormann CF. *Parametrische Statistik: Verteilungen, maximum likelihood und GLM in R*. 2nd ed. Berlin, Heidelberg: Springer Berlin Heidelberg; 2017.
166. *A primer on partial least squares structural equation modeling (PLS-SEM)*. Los Angeles, Calif.: Sage; 2014.
167. Bulmer M. *Principles of statistics*. 1967th ed. New York: Dover Publications Inc; 1979.
168. George D, Mallery P. *SPSS for Windows step by step: A simple guide and reference, 17.0 update*. 10th ed. Boston: Allyn & Bacon; 2010.
169. Kronthaler F. *Statistik angewandt: Datenanalyse ist (k)eine Kunst Excel Edition*. 1st ed. Berlin, Heidelberg: Springer Spektrum; 2016.
170. Peacock J, Peacock P. *Oxford handbook of medical statistics*. 1st ed. Oxford: Oxford Univ. Press; 2011.
171. Croux C, Dehon C. Influence functions of the Spearman and Kendall correlation measures. *Stat Methods Appl*. 2010;19:497–515. doi:10.1007/s10260-010-0142-z.
172. Cohen J. *Statistical power analysis for the behavioral sciences*. 2nd ed. Hillsdale, NJ: Erlbaum; 1988.

-
173. Raschka S, Mirjalili V. Machine Learning mit Python und Keras, TensorFlow 2 und Scikit-Learn. 3rd ed. Erscheinungsort nicht ermittelbar, Boston, MA: mitp Verlag; Safari; 2021.
174. Hebing M, Manhembué M. Data Science Management: Vom ersten Konzept bis zur Governance datengetriebener Organisationen. Heidelberg: o'Reilly; 2024.
175. Hirschle J. Machine Learning für Zeitreihen: Einstieg in Regressions-, ARIMA- und Deep Learning-Verfahren mit Python. München: Hanser; 2021.
176. Team K. Keras documentation: Optimizers. 02.08.2023. <https://keras.io/api/optimizers/>. Accessed 6 Aug 2023.
177. Zillow Prize: Zillow's Home Value Prediction (Zestimate). 16.02.2024. <https://www.kaggle.com/c/zillow-prize-1/data>. Accessed 16 Feb 2024.
178. Thapa S. Ames Housing Dataset. 20.06.2023. <https://www.kaggle.com/datasets/shashanknecrothapa/ames-housing-dataset>. Accessed 16 Feb 2024.
179. Nugent C. California Housing Prices. 24.11.2017. <https://www.kaggle.com/datasets/camnugent/california-housing-prices>. Accessed 6 Aug 2023.
180. Pace K, Barry R. California Housing Dataset. 06.11.2019. https://www.dcc.fc.up.pt/~ltorgo/Regression/cal_housing.html. Accessed 20 Aug 2023.
181. Pace K, Barry R. Sparse spatial autoregressions. *Statistics & Probability Letters*. 1997;33:291–7.
182. scikit-learn. scikit-learn Webseite - sklearn.datasets.fetch_california_housing. 20.08.2023. https://scikit-learn.org/stable/modules/generated/sklearn.datasets.fetch_california_housing.html. Accessed 20 Aug 2023.
183. Harrison D, Rubinfeld DL. Hedonic housing prices and the demand for clean air. *Journal of Environmental Economics and Management*. 1978;5:81–102. doi:10.1016/0095-0696(78)90006-2.
184. Boston Dataset. 16.10.1996. <https://www.cs.toronto.edu/~delve/data/boston/bostonDetail.html>. Accessed 6 Aug 2023.
185. prasadperera. Kaggle Webseite - The Boston Housing Dataset. Kaggle. 03.05.2018.
186. Shahhosseini M, Hu G, Pham H. Optimizing Ensemble Weights for Machine Learning Models: A Case Study for Housing Price Prediction. In: Yang H, editor. *Smart Service Systems, Operations Management, and Analytics: Proceedings of the 2019 INFORMS International Conference on Service Science*. Cham: Springer International Publishing AG; 2020. p. 87–97. doi:10.1007/978-3-030-30967-1_9.
187. Bataineh AA, Kaur D. A Comparative Study of Different Curve Fitting Algorithms in Artificial Neural Network using Housing Dataset. In: *NAECON 2018 - IEEE National Aerospace and Electronics Conference; 7/23/2018 - 7/26/2018; Dayton, OH, USA*. Piscataway, NJ: IEEE; 2018. p. 174–178. doi:10.1109/NAECON.2018.8556738.
188. Tipping M. The Relevance Vector Machine. In: S. Solla, T. Leen, K. Müller, editors: MIT Press; 1999.

-
189. Hilde Weerts, Miroslav Dudík, Richard Edgar, Adrin Jalali, Roman Lutz, Michael Madaio. Fairlearn: Assessing and Improving Fairness of AI System - Revisiting the Boston Housing Dataset — Fairlearn 0.10.0.dev0 documentation. 2023. https://fairlearn.org/main/user_guide/datasets/boston_housing_data.html#footcite-uscensusbureau-metropolitan. Accessed 20 Aug 2023.
190. scikit-learn. Webseite scikit-learn - sklearn.datasets.load_boston. 20.08.2023. https://scikit-learn.org/1.0/modules/generated/sklearn.datasets.load_boston.html. Accessed 20 Aug 2023.
191. Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen. Informationsportal Nachhaltiges Bauen des Bundesministerium für Wohnen, Stadtentwicklung und Bauwesen: Nutzungsdauern von Bauteilen. 21.08.2023. <https://www.nachhaltigesbauen.de/aus-tausch/nutzungsdauern-von-bauteilen/>. Accessed 21 Aug 2023.
192. Institut für Erhaltung und Modernisierung von Bauwerken e.V. (IEMB). Lebensdauer von Bauteilen und Bauteilschichten (Info-Blatt Nr. 4.2): Tragkonstruktion, Nichttragende Konstruktion, Installationen und betriebstechnische Anlagen, Außenanlagen. Berlin; 2009.
193. Wetter und Klima - Deutscher Wetterdienst - Überblick. 10.03.2024. https://www.dwd.de/DE/klimaumwelt/klimawandel/ueberblick/ueberblick_node.html. Accessed 10 Mar 2024.
194. Winnemöller. Stadt und Gemeinde; 1997.
195. Deutscher Städte- und Gemeindebund. DStGB Dokumentation No 8: Kommunales Immobilienmanagement. 5th ed. Berlin; 1999.
196. Landeshauptstadt Mainz. Statistische Informationen zur Stadtentwicklung 2020: Landeshauptstadt Mainz. Mainz; 2020.
197. Stadtrat der Stadt Mainz. Haushaltsplan 2023/2024 der Landeshauptstadt Mainz: BAND-1-Aenderung-EB_Satzung. Mainz; 22.12.2022.

Lebenslauf

Persönliche Daten

Name Daniel Ralf Jonathan Walter

Staatsangehörigkeit Deutsch

Beruflicher Werdegang

12/2023 - heute **BMW Group**

Immobilien Projekt Management

01/2023 - heute **DBC Consulting GmbH**

Senior Software Developer

10/2020 – heute **Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau**

Doktorand (Dr.-Ing.) im Fachbereich Bauingenieurwesen.

Titel: "KI-gestütztes adaptives Modell zur Optimierung der Lebensdauerprognosen von Bauelementen unter Berücksichtigung spezifischer Einflussfaktoren".

06/2019 – 11/2022 **LifeCycle-Competence GmbH & Co. KG**

Senior Software Developer

09/2017 – 11/2023 **Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau**

Wissenschaftlicher Mitarbeiter am Fachgebiet Baubetrieb und Bauwirtschaft des Fachbereiches Bauingenieurwesen.

Ausbildung

2020 - 2024 **Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau**

Doktoringenieur (Dr.-Ing.), Bauingenieurwesen

2014 - 2017 **Hochschule Kaiserslautern**

Master of Science, Informatik (M. Sc.)

2010 - 2014 **Hochschule Kaiserslautern**

Bachelor of Science, Medien Informatik (B. Sc.)

2001 - 2009 **Von der Leyen Gymnasium Blieskastel**

Abitur

| Ehrenamt | |
|-----------------|--|
| 2023 - heute | DIN - Deutsches Institut für Normung: Working Committee NA 043-01-42 GA "Artificial Intelligence". |
| 2022 - 2024 | BIM Cluster Rheinland-Pfalz Koordinierungskreis |
| 2014 - 2015 | Präsident des Studierendenparlaments der Hochschule Kaiserslautern, Standort Zweibrücken |
| 2013 - 2014 | Vize-Präsident des Studierendenparlaments der Hochschule Kaiserslautern, Standort Zweibrücken |
| 2013 - 2014 | Mitglied des Allgemeinen Studierendenausschusses der Hochschule Kaiserslautern, Standort Zweibrücken |
| 2013 - 2014 | Vorstand des Finanzprüfungsausschusses der Hochschule Kaiserslautern, Standort Zweibrücken |
| 2013 - 2014 | Vorstand des Wahlprüfungsausschusses der Hochschule Kaiserslautern, Standort Zweibrücken |

Kaiserslautern, 14.06.2024 Daniel Walter