Abschlussarbeit

zur Erlangung des

Master of Advanced Studies in Real Estate

Einsatz von Künstlicher Intelligenz zur Analyse unstrukturierter Gebäudedaten im Real Estate Portfolio-Management

Ein Transfer-Ansatz von UK-Best Practices
auf institutionelle Investoren in der Schweiz

Verfasserin:	Senn, Anina
	Zweierstrasse 185, 8003 Zürich

Eingereicht bei:	Dr. Fabian Wildenauer
Abgabedatum:	04.09.2026

Inhaltsverzeichnis

1 Einleitung…….. 1
1.1 Ausgangslage 1
1.2 Zielsetzung und Forschungsfrage 2
1.3 Abgrenzung des Themas 3
1.4 Vorgehen 4
2 Theoretische Grundlagen 7
2.1 Begriffliche Einordnung 7
2.1.1 Künstliche Intelligenz, Machine Learning und NLP 7
2.1.2 Strukturierte versus unstrukturierte Daten 8
2.1.3 Asset Management versus Portfolio Management 9
2.2 Informationsökonomie und Transaktionskostentheorie 11
2.3 AI-Entwicklungen in der Immobilienwirtschaft 14
2.4 Asset- versus Portfolio-Ebene: die Aggregationslücke 18
2.5 Herleitung des Marktvergleichs UK versus Schweiz 20
2.6 Forschungslücke 22
3 Empirische Untersuchung 27
3.1 Forschungsdesign und Methodik 27
3.2 Datenerhebung 29
3.3 Auswahl der Interviewpartner 30
3.4 Auswertungsmethode 33
3.5 Ergebnisse der Experteninterviews 35
3.5.1 Ergebnislogik und Darstellungsweise 35
3.5.2 Reifegrad: Zwischen Experimentieren, Pilotierung und punktueller Integration 36
3.5.3 Datenqualität als bindende Restriktion 38
3.5.4 Die Aggregationslücke zwischen Asset- und Portfolioebene 40

3.5.5 Governance, Kontrolle und Haftung 41
3.5.6 Akzeptanz und Kompetenzaufbau 42
3.5.7 Verdichtung der empirischen Befunde 43
3.6 UK-Vergleich und Transferperspektive 44
3.6.1 Marktreife und institutioneller Datenkontext 45
3.6.2 Relevante Datenquellen und Research-Integration 46
3.6.3 Entscheidungsintegration und Human-in-the-Loop 47
3.6.4 Transferierbare Praktiken aus dem UK-Markt 49
3.6.5 Grenzen der Übertragbarkeit 50
4 Schlussbetrachtung 52
4.1 Fazit 52
4.2 Diskussion und kritische Würdigung 54
4.3 Ausblick 57
Literaturverzeichnis 59
Anhang 66
Anhang 1: Interviewleitfaden 66
Themenblock A: Strategische Einordnung und Vision 66
Themenblock B: KI-Methoden und unstrukturierte Daten 66
Themenblock C: Nutzen und Entscheidungsgüte 67
Themenblock D: Implementierung und internationaler Transfer 67
Anhang 2: Liste der Interviewpartner 68
Anhang 3: Codierschema (Endfassung) 69

Abkürzungsverzeichnis

AI	Artificial Intelligence (Künstliche Intelligenz)
AVM	Automated Valuation Model
CAPEX	Capital Expenditures (Investitionsausgaben)
CRE	Commercial Real Estate
CUREM	Center for Urban & Real Estate Management, Universität Zürich
DACH	Deutschland, Österreich, Schweiz
ERP	Enterprise Resource Planning
ESG	Environmental, Social, Governance
GRETI	Global Real Estate Transparency Index
IoT	Internet of Things
KI	Künstliche Intelligenz
LLM	Large Language Model
MAS	Master of Advanced Studies
ML	Machine Learning
NLP	Natural Language Processing
OCR	Optical Character Recognition
PropTech	Property Technology
RICS	Royal Institution of Chartered Surveyors
SLR	Systematic Literature Review
UK	United Kingdom (Vereinigtes Königreich)

Abbildungsverzeichnis

Abbildung 1: Argumentationsstruktur und Aufbau der Arbeit (eigene Darstellung)..... 5
Abbildung 2: Hierarchische Einordnung KI, ML, Deep Learning und NLP (eigene Darstellung) 8
Abbildung 3: Vertikale Wertschöpfungskette und Datenfluss von der Objekt- zur Portfolioebene im institutionellen Immobilienmanagement (eigene Darstellung) 11
Abbildung 4: Konzeptioneller Rahmen der Arbeit (eigene Darstellung)..... 24
Abbildung 5: Forschungsdesign im Überblick (eigene Darstellung) 29

Tabellenverzeichnis

Tabelle 1: PropTech-Cluster nach Braesemann und Baum (2020)……... 15

Tabelle 2: Vergleich zwischen UK und Schweiz nach Schlüsselindikatoren…… 21

Tabelle 3a: Deduktive Hauptkategorien……..… 34

Tabelle 3b: Induktive Subkategorien……. 35

Executive Summary

Die institutionelle Immobilienwirtschaft steht vor der Herausforderung, wachsende Bestände unstrukturierter Daten, etwa aus Mietverträgen, technischen Berichten oder Wartungsprotokollen, nicht nur effizient zu verarbeiten, sondern für strategische Portfolioentscheidungen nutzbar zu machen. Während Künstliche Intelligenz (KI) im Asset Management bereits vielfältige Anwendungen findet, bleibt die Nutzung unstrukturierter Daten auf Portfolioebene weitgehend unerschlossen. Die vorliegende Arbeit untersucht, wie institutionelle Immobilieninvestoren in der Schweiz durch den Einsatz von KI im Immobilien-Portfolio-Management Effizienz- und Effektivitätsgewinne erzielen können und welche Erkenntnisse sich aus dem britischen Markt übertragen lassen.

Die Untersuchung basiert auf einem qualitativ-explorativen Forschungsdesign. Der theoretische Teil verankert die Fragestellung in der Informationsökonomie und Transaktionskostentheorie, grenzt Asset- und Portfolio-Management voneinander ab und analysiert den aktuellen Forschungsstand. Im empirischen Teil wurden elf leitfadengestützte Experteninterviews mit institutionellen Investoren in der Schweiz und im Vereinigten Königreich durchgeführt und mittels qualitativer Inhaltsanalyse ausgewertet.

Die Ergebnisse zeigen eine deutliche Lücke zwischen der objektbezogenen KI-Nutzung und ihrer Anwendung in der strategischen Portfoliosteuerung. Der Schweizer Markt befindet sich überwiegend in einer frühen Entwicklungsphase; produktive Anwendungen finden sich vor allem dort, wo Daten bereits strukturiert vorliegen. Als zentrale Voraussetzung erweist sich die Datenqualität, deren Bedeutung die Leistungsfähigkeit der eingesetzten Modelle übersteigt. Zudem bestätigt sich die Aggregationslücke als soziotechnisches Phänomen: KI verbindet Objekt- und Portfolioebene, ersetzt jedoch keine fachlichen Entscheidungsprozesse. Governance, Kontrolle und Haftung sind zentrale Erfolgsfaktoren, weshalb Human-in-the-Loop-Strukturen dauerhaft erforderlich bleiben. Ebenso stellen Akzeptanz und Kompetenzaufbau wesentliche Voraussetzungen für eine erfolgreiche Implementierung dar. Aus dem britischen Markt werden Best Practices hinsichtlich Datenstandardisierung, organisatorischer Verankerung und PropTech-Adoption abgeleitet. Deren Übertragbarkeit auf die Schweiz wird unter Berücksichtigung struktureller, regulatorischer und kultureller Unterschiede diskutiert. Daraus leitet die Arbeit konkrete Handlungsempfehlungen für institutionelle Immobilieninvestoren ab, um den Übergang zu einer datengetriebenen Portfoliosteuerung zu unterstützen.

1 Einleitung

Das einleitende Kapitel führt die Ausgangslage ein, formuliert Zielsetzung und Forschungsfrage, grenzt den Untersuchungsgegenstand ab und erläutert das methodische Vorgehen.

1.1 Ausgangslage

Die institutionelle Immobilienwirtschaft befindet sich in einem fundamentalen Wandel. Während andere Anlageklassen längst datengetriebene Entscheidungsprozesse etabliert haben, gilt der Immobilienmarkt nach wie vor als informationsineffizient, fragmentiert und intransparent (Baum et al., 2020, S. 6, 16; Trübestein, 2012, S. 19). Diese strukturelle Eigenheit ist nicht zufällig: Immobilien sind heterogene, illiquide und durch lokale Besonderheiten geprägte Vermögenswerte, deren Bewertung und Steuerung in der Regel auf einer Vielzahl unstrukturierter Dokumente basiert: Mietverträge, technische Gutachten, Wartungsprotokolle, Baupläne und Korrespondenzen mit Mieterinnen und Mietern.

Mit der rasanten Entwicklung von Methoden der Künstlichen Intelligenz, insbesondere im Bereich Natural Language Processing (NLP) und Computer Vision, eröffnen sich neuartige Möglichkeiten, diese unstrukturierten Datenbestände systematisch zu erschliessen (Karpook & Wu, 2025, S. 210; Zhao et al., 2026, S. 122). Die McKinsey-Schätzung beziffert das jährliche Wertschöpfungspotenzial generativer KI für die Immobilienbranche auf 110 bis 180 Milliarden US-Dollar weltweit (McKinsey & Company, 2023, S. 5). Praxisorientierte Untersuchungen zeigen, dass KI-gestützte Anwendungen bereits heute in Bewertung, Vermietung, Property Management und Investitionsentscheidungen eingesetzt werden (Deloitte, 2023, S. 12; JLL, 2024a, S. 18).

Trotz dieser Dynamik konzentriert sich der Einsatz von KI bislang überwiegend auf die operative Ebene des Asset Managements, also auf einzelne Liegenschaften. Automatisierte Bewertungsmodelle (AVM), Vertragsabstraktion auf Objektebene und Predictive Maintenance dominieren die Anwendungsfälle (Karpook & Wu, 2025, S. 210). Die strategisch entscheidende Aggregation dieser Informationen zu portfolioweiten Steuerungsgrössen (etwa zur Identifikation von Klumpenrisiken, zur vorausschauenden CAPEX-Planung oder zur datengetriebenen Exit-Strategie) bleibt hingegen weitgehend unausge-

schöpft (KTH Royal Institute of Technology, 2025, S. 14; Vigren & Eriksson, 2025, S. 173).

Diese Diskrepanz wird in der Literatur als Aggregationslücke beschrieben: Während die Datengewinnung auf Asset-Ebene zunehmend automatisiert ist, fehlen vielen institutionellen Investoren die organisatorischen und technischen Voraussetzungen, um aus diesen Daten portfolioweite Erkenntnisse abzuleiten (Saull & Baum, 2020, S. 14, 18). Die Folge ist ein paradoxes Bild: Das Datenreichtum auf Objektebene wächst, doch die strategische Steuerung des Gesamtportfolios bleibt erfahrungsbasiert, manuell und anfällig für blinde Flecken.

Im internationalen Vergleich nimmt das Vereinigte Königreich eine Vorreiterrolle ein. Der Global Real Estate Transparency Index (GRETI) 2024 weist Grossbritannien zum wiederholten Mal als transparentesten Immobilienmarkt der Welt aus (JLL & LaSalle, 2024). Die britische PropTech-Szene zählt europaweit über 3'219 PropTech-Unternehmen, wobei das Vereinigte Königreich den grössten Anteil am Funding-Volumen auf sich vereint, und weist ein institutionelles Investitionsvolumen auf, das die kontinentaleuropäischen Märkte deutlich übertrifft (Baum et al., 2020, S. 23-24). Die Schweiz verfügt zwar über einen hochentwickelten institutionellen Immobilienmarkt mit einem Anlagevolumen kotierter Vehikel von rund 70 Milliarden Schweizer Franken (UBS, 2024, S. 8), ist im GRETI jedoch auf Position 14 eingestuft und weist mit knapp 500 PropTech-Unternehmen eine deutlich kleinere Innovationsbasis auf (SwissPropTech, 2025, S. 11).

Diese strukturelle Asymmetrie wirft die Frage auf, welche Praktiken aus dem britischen Markt für Schweizer institutionelle Investoren übertragbar sind und unter welchen Bedingungen ein erfolgreicher Transfer gelingen kann. Ein systematischer Marktvergleich bietet sich an, da beide Märkte von finanzstarken, risikosensitiven institutionellen Akteuren geprägt sind und trotz des unterschiedlichen technologischen Reifegrades vor identischen strategischen Herausforderungen stehen: der Notwendigkeit einer transparenten ESG-Berichterstattung, steigenden regulatorischen Offenlegungspflichten und einem zunehmenden Kapitaldruck.

1.2 Zielsetzung und Forschungsfrage

Vor dem skizzierten Hintergrund verfolgt die vorliegende Arbeit das Ziel, das Potenzial Künstlicher Intelligenz für das institutionelle Portfolio Management in der Schweiz zu

untersuchen und konkrete Handlungsempfehlungen abzuleiten. Im Zentrum steht die Erschliessung unstrukturierter Datenbestände durch KI-Methoden, insbesondere NLP und Machine Learning, mit dem Ziel, von der einzelobjektbezogenen Datennutzung zu einer aggregierten, portfolioweiten Steuerung zu gelangen.

Die übergeordnete Forschungsfrage der Arbeit lautet:

Wie können institutionelle Immobilieninvestoren im Portfoliomanagement in der Schweiz durch den Einsatz von Künstlicher Intelligenz effizienter und effektiver werden, und welche Implementierungsstrategien lassen sich aus dem UK-Markt ableiten?

Zur strukturierten Beantwortung dieser Hauptfrage werden zwei Unterfragen formuliert:

- *Welche strukturellen und organisatorischen Voraussetzungen ermöglichen im britischen Markt die Übersetzung KI-gestützter Objektdaten in portfolioweite Steuerungsgrössen?*
- *Welche strukturellen Bedingungen (Datenqualität, Governance, Akzeptanz) prägen den Reifegrad der KI-Nutzung bei institutionellen Immobilieninvestoren in der Schweiz, und welche Handlungsfelder lassen sich daraus ableiten?*

Die Arbeit ist explorativ angelegt und verfolgt einen Erkenntnisbeitrag in dreifacher Hinsicht: theoretisch durch die Schärfung der Abgrenzung zwischen Asset- und Portfolio-Management im Kontext datengetriebener Steuerung, empirisch durch die Erhebung von Primärdaten in beiden Märkten sowie praxisbezogen durch die Ableitung von Handlungsempfehlungen für Schweizer Investoren.

1.3 Abgrenzung des Themas

Die thematische Eingrenzung erfolgt entlang von drei Dimensionen. Erstens fokussiert die Arbeit auf institutionelle Immobilieninvestoren (Pensionskassen, Versicherungen, Anlagestiftungen, Immobilien-AGs und Fondsanbieter) und schliesst Privatinvestoren, Eigennutzer und Projektentwickler aus. Diese Eingrenzung folgt der Beobachtung, dass die Aggregationsproblematik vor allem bei Akteuren mit grossen, diversifizierten Portfolios auftritt und dort die grössten Effizienzgewinne erwartet werden können (Saull & Baum, 2020, S. 11-12).

Zweitens beschränkt sich die Arbeit auf die strategische Ebene des Portfolio Managements und grenzt sich vom operativen Asset und Property Management ab. Wo Anwen-

dungsfälle aus dem Asset Management beleuchtet werden, geschieht dies ausschliesslich, um die Aggregationslücke zur Portfolio-Ebene zu illustrieren. Die Bewertungsmethodik einzelner Liegenschaften, automatisierte Bewertungsmodelle (AVM) im engeren Sinne sowie Mietspiegelmodelle sind nicht Gegenstand der Untersuchung.

Drittens beschränkt sich die Arbeit auf KI-Methoden zur Erschliessung unstrukturierter Daten, primär Natural Language Processing für textuelle Inhalte. Quantitative Modelle auf strukturierten Daten (etwa klassische Regressionsmodelle oder Time-Series-Analysen) werden zwar in der theoretischen Einbettung erwähnt, stehen jedoch nicht im Zentrum der Analyse.

Geografisch konzentriert sich die Untersuchung auf den Schweizer Markt als Zielmarkt und den britischen Markt als Referenzmarkt. Andere reife Märkte (USA, Deutschland, Skandinavien) werden punktuell zur Einordnung herangezogen, sind jedoch nicht Vergleichsmärkte im engeren Sinne.

1.4 Vorgehen

Die Arbeit gliedert sich nach Einleitung, Theorie, Empirie und Schlussbetrachtung. Kapitel 2 entwickelt die theoretischen Grundlagen entlang dreier inhaltlicher Blöcke: einer begrifflichen Einordnung von KI, Machine Learning, NLP sowie der Differenzierung von Asset- und Portfolio-Management, einer informationsökonomischen und transaktionskostentheoretischen Verankerung der Fragestellung sowie einer Aufarbeitung des Forschungsstands zur KI-Nutzung in der Immobilienwirtschaft, mit besonderem Fokus auf die Aggregationslücke zwischen Asset- und Portfolio-Ebene und die Herleitung des Marktvergleichs zwischen der Schweiz und UK. Aus dieser Aufarbeitung wird in Abschnitt 2.6 die Forschungslücke explizit benannt.

Kapitel 3 beschreibt das qualitativ-explorative Forschungsdesign, die Auswahl der Interviewpartner, das Vorgehen bei der Datenerhebung sowie die Auswertungsmethode in Form einer qualitativen Inhaltsanalyse. Anschliessend werden die Ergebnisse der elf leitfadengestützten Experteninterviews (davon zwei Doppel-Interviews) entlang der Themenblöcke des Interviewleitfadens präsentiert. Kapitel 4 fasst die Erkenntnisse in einem Fazit zusammen, diskutiert die Übertragbarkeit der UK-Praktiken auf den schweizerischen Kontext, leitet Handlungsempfehlungen ab und ordnet die Aussagekraft der Arbeit kritisch ein. Den Abschluss bildet ein Ausblick auf weiterführende Forschungsfragen.

Die Argumentationsstruktur der Arbeit lässt sich auf drei aufeinander aufbauende Blöcke verdichten, die in Abbildung 1 schematisch dargestellt sind: (I) Überblick über die



KI-Entwicklungen in der Immobilienwirtschaft, (II) Differenzierung der KI-Nutzung auf Asset- gegenüber Portfolio-Ebene und Identifikation der Aggregationslücke, sowie (III) Herleitung des Marktvergleichs zwischen UK und Schweiz und Diskussion der Übertragbarkeit von Best Practices.

Abbildung 1: Argumentationsstruktur und Aufbau der Arbeit (eigene Darstellung)

Die wirtschaftliche Tragweite der Aggregationsfrage lässt sich an einem einfachen Rechenbeispiel illustrieren. Schweizer institutionelle Investoren halten gemäss aktuellen empirischen Erhebungen und Marktschätzungen Immobilienwerte von insgesamt rund 835.3 Milliarden Schweizer Franken (Bundesamt für Statistik (BFS), 2026, S. 2; Institut für Finanzdienstleistungen Zug (HSLU), 2025, S. 14). Diese Summe setzt sich zusammen aus der jüngsten Real-Estate-Investment-Studie der HSLU (2025, S. 14), bei der bereits eine Teilmenge von 228 befragten Institutionen ein Gesamtanlagevolumen von 568 Milliarden Franken auswies, sowie den gesamten (direkten und indirekten) Immobilienwerten der Schweizer Pensionskassen, die sich gemäss den definitiven Ergebnissen des BFS (2026, S. 1-2) per Ende 2024 auf rund 267.3 Milliarden Franken beliefen.

Grundlage waren eine Bilanzsumme von 1'220.6 Milliarden Franken und eine Immobilienquote von 21.9%.

Eine Verbesserung der Portfoliorenditen um nur 25 Basispunkte, etwa durch die frühere Identifikation von Klumpenrisiken oder eine vorausschauende CAPEX-Steuerung, entspricht einem aggregierten Wertbeitrag von rund 2.09 Milliarden Schweizer Franken pro Jahr, selbst bei konservativer Annahme im dreistelligen Millionenbereich. Diese Grössenordnung verdeutlicht, dass die Aggregationsfrage keine Detailfrage operativer Effizienz, sondern eine strategische Wertschöpfungsfrage von volkswirtschaftlicher Relevanz ist.

Die Forschungsmotivation ist zudem durch den unmittelbaren Praxisbezug der Verfasserin geprägt. Die im Rahmen des MAS-Studiums absolvierten Module wie beispielsweise Real Estate Finance und Portfolio-Management haben die strukturelle Bedeutung qualitativer und unstrukturierter Daten für strategische Entscheidungen wiederholt illustriert. Die Beobachtung, dass die akademische Diskussion um KI in der Immobilienwirtschaft bislang stark auf operativen Anwendungen ruht, während die strategische Aggregationsdimension wenig adressiert ist, war ein zentraler Auslöser der vorliegenden Untersuchung.

2 Theoretische Grundlagen

Das vorliegende Kapitel verankert die Forschungsfrage in der wissenschaftlichen Literatur. Abschnitt 2.1 grenzt zentrale Begriffe ab. Abschnitt 2.2 entwickelt die theoretische Fundierung über Informationsökonomie und Transaktionskostentheorie. Abschnitt 2.3 gibt einen Überblick über die KI-Entwicklungen in der Immobilienwirtschaft. Abschnitt 2.4 arbeitet die Differenzierung zwischen Asset- und Portfolio-Ebene heraus und identifiziert die Aggregationslücke als zentrales Phänomen. Abschnitt 2.5 begründet den Marktvergleich zwischen der Schweiz und UK und Abschnitt 2.6 zeigt die Forschungslücke auf.

2.1 Begriffliche Einordnung

Der folgende Abschnitt klärt die zentralen Begriffe, auf denen die weitere Argumentation aufbaut.

2.1.1 Künstliche Intelligenz, Machine Learning und NLP

Künstliche Intelligenz (KI) ist ein Sammelbegriff für computergestützte Verfahren, die Aufgaben bewältigen, welche typischerweise menschliche Intelligenz erfordern. Russell und Norvig (2021, S. 19) definieren KI als das Studium von Agenten, die ihre Umwelt wahrnehmen und Handlungen ausführen, um ihre Erfolgswahrscheinlichkeit bei der Erreichung definierter Ziele zu maximieren. Diese funktionale Definition umfasst sowohl regelbasierte Expertensysteme als auch lernende Verfahren.

Machine Learning (ML) ist ein Teilgebiet der KI, das Algorithmen entwickelt, die aus Daten lernen, ohne explizit programmiert zu werden. Goodfellow et al. (2016, S. 105-106) unterscheiden dabei drei wesentliche Lernparadigmen: das überwachte Lernen (mit gelabelten Trainingsdaten), das unüberwachte Lernen (ohne vordefinierte Label) und das Verstärkungslernen (Lernen durch Belohnungssignale). Im Immobilienkontext dominieren derzeit überwachte Verfahren, beispielsweise beim Training von automatisierten Bewertungsmodellen (Deppner et al., 2023, S. 314) oder bei Klassifikatoren für spezifische Vertragsklauseln (vgl. Adediran et al., 2026, S. 201).

Deep Learning bezeichnet eine spezielle Klasse von Machine-Learning-Verfahren auf Basis künstlicher neuronaler Netze mit mehreren verborgenen Schichten. Mit dem Aufkommen leistungsfähiger GPU-Hardware und der Verfügbarkeit großer Datenmengen

ermöglichten Deep-Learning-Architekturen ab etwa 2012 substanzielle Durchbrüche in den Bereichen Sprach-, Bild- und Texterkennung (LeCun et al., 2015, S. 436).

Natural Language Processing (NLP) ist jener Zweig der KI, der sich mit der maschinellen Verarbeitung und dem Verstehen natürlicher Sprache befasst. Klassische NLP-Aufgaben umfassen die Textklassifikation, die Extraktion benannter Entitäten (Named Entity Recognition, NER), die Sentiment-Analyse sowie die maschinelle Übersetzung (Jurafsky & Martin, 2026, S. 45). Mit der Einführung der Transformer-Architektur durch Vaswani et al. (2017, S. 3) und der nachfolgenden Entwicklung großer Sprachmodelle (Large Language Models, LLMs) erreichte NLP eine neue evolutionäre Leistungsstufe. Diese Technologie rückt nun auch hochgradig domänenspezifische Anwendungen wie die automatisierte Strukturierung und Analyse komplexer Mietverträge oder technischer Immobilienberichte in den Fokus der betrieblichen Praxis (vgl. Adediran et al., 2026, S. 223-224; Zhao et al., 2026, S. 121-122).

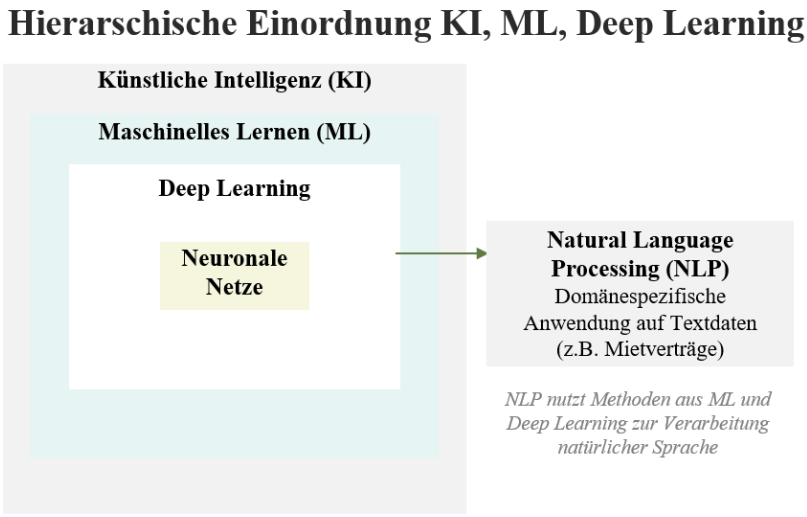


Abbildung 2: Hierarchische Einordnung KI, ML, Deep Learning und NLP (eigene Darstellung)

Computer Vision beschreibt schliesslich jenen Zweig der KI, der die maschinelle Interpretation und Analyse visueller Informationen behandelt. Im Immobiliensektor findet Computer Vision zunehmend Anwendung in der automatisierten Auswertung von Grundrissen sowie in der Analyse von Drohnenaufnahmen zur Zustandsbeurteilung von Gebäuden und Fassaden (vgl. Naeem et al., 2023, S. 11).

2.1.2 Strukturierte versus unstrukturierte Daten

Die Unterscheidung zwischen strukturierten und unstrukturierten Daten ist für die vorliegende Arbeit von zentraler Bedeutung. Strukturierte Daten liegen in tabellarischer Form mit klar definierten Feldern und Datentypen vor. Sie sind typischerweise in relati-

onalen Datenbanken oder Enterprise-Resource-Planning-Systemen (ERP) gespeichert. Typische Beispiele aus der Immobilienwirtschaft umfassen strukturierte Mietzinslisten, transaktionale Buchungsdaten, physikalische Flächenangaben sowie normierte Marktdaten aus etablierten Datenbanken wie Wüest Partner, IAZI oder REIDA.

Unstrukturierte Daten hingegen folgen keinem vordefinierten Datenmodell. Dazu zählen freie Texte (wie Mietverträge, Gutachten, E-Mails und Korrespondenzen), Bilddateien (wie Fotos, Pläne und Drohnenaufnahmen), Audio- und Videoaufzeichnungen sowie unformatierte PDF-Dokumente. Während ein breiter Branchenkonsens davon ausgeht, dass unstrukturierte Daten rund 80 bis 90 Prozent des weltweiten Datenvolumens ausmachen (vgl. IBM, 2015; für das exponentielle Wachstum von Big-Data-Strukturen siehe auch Manyika et al., 2011), zeigt sich diese informationstechnische Herausforderung im Immobiliensektor in noch schärferer Form.

Gemäss aktuellen PropTech- und Technologie-Benchmarks generieren moderne Immobilienbestände pro Liegenschaft jährlich rund 2.3 Terabytes an Rohdaten. In der Praxis können traditionelle Akteure davon jedoch weniger als 20 Prozent effektiv analysieren, da wertschöpfungsrelevante Informationen (wie mietrechtliche Sonderkonditionen, bauliche Mängel in technischen Berichten oder behördliche Auflagen) meist dezentral in unstrukturierten Freitexten und analogen Dokumentensilos vergraben bleiben (vgl. Saull & Baum, 2020, S. 14; Węgrzyn, 2026, S. 1).

Die systematische Erschliessung und Strukturierung dieser unstrukturierten Datenbestände bildet die zentrale technische Hürde bei der Digitalisierung von Immobilienportfolios. Während starre, regelbasierte IT-Systeme an der hohen linguistischen Variabilität natürlicher Sprache scheitern, ermöglichen moderne, transformerbasierte Sprachmodelle (LLMs) eine kontextsensitive Extraktion, Klassifikation und Aggregation dieser ungenutzten Datenpools zu strategischen Portfoliokenngrössen.

2.1.3 Asset Management versus Portfolio Management

Die zentrale konzeptionelle Unterscheidung dieser Arbeit betrifft die Abgrenzung zwischen dem operativen beziehungsweise taktischen Asset Management und dem strategischen Portfolio Management. In der institutionellen Immobilienökonomie beschreibt das Asset Management (AM) die wertorientierte Steuerung einzelner Liegenschaften oder lokaler Teilportfolios mit dem Ziel, die Performance auf Objektebene während der Haltephase zu maximieren (Kämpf-Dern, 2009, S. 9). Das Aufgabenspektrum ist stark objekt- und mieterorientiert: Es umfasst Mietvertragsverhandlungen, die Definition ob-

jektspezifischer Vermietungsstrategien, operative Instandhaltungs- und Investitionsentscheidungen (CAPEX) sowie das proaktive Management und Controlling der externen Dienstleister aus dem Property- und Facility Management (Pfnür, 2011, S. 41-43; gif, 2004, S. 8).

Das Portfolio Management (PM) hingegen agiert auf einer übergeordneten, strategischen Ebene und betrachtet den Immobilienbestand als Gesamtheit finanzieller Vermögenswerte (Chambers et al., 2020, S. 42). Zu den Kernaufgaben gehören die Definition der Asset Allokation und Diversifikationsstrategie, die Steuerung von Risiken über Nutzungsarten, Branchen und Regionen hinweg sowie die Festlegung von Risiko-Benchmarks (Ropeter-Ahlers & Vollrath, 2007, S. 160). Entscheidungen auf dieser Ebene basieren primär auf aggregierten Kennzahlen wie dem portfolioübergreifenden Total Return, der Sharpe Ratio, dem Tracking Error gegenüber Markt-Indizes oder der Identifikation von Klumpenrisiken bezüglich Vertragslaufzeiten (WALT) und Mieterbonitäten (Anson, 2012, S. 67; Chambers et al., 2020, S. 45).

Während diese vertikale Trennung in der Theorie präzise definiert ist (gif, 2004, S. 5), erweist sie sich in der immobilienwirtschaftlichen Praxis oft als fliessend. Dies ist zum einen auf unterschiedliche Begriffsinterpretationen im angelsächsischen und kontinentaleuropäischen Raum zurückzuführen. Während im angelsächsischen Verständnis der Begriff «Asset Management» oft als Oberbegriff verwendet wird, der strategische Portfolioentscheidungen einschliesst, dominiert in der Schweiz und in Deutschland die hierarchische Dreiteilung der gif (2004, S. 6) in Investment, Portfolio und Asset Management. Zum anderen führen personelle und organisatorische Ressourcenengpässe, insbesondere bei kleineren und mittleren Schweizer Vorsorgeeinrichtungen, im Alltag oft zu einer personellen Zusammenlegung dieser Rollen (Swisscanto, 2026, S. 34).

Für die vorliegende Arbeit ist die analytische Trennung dennoch von fundamentaler Bedeutung, da sich die strategische Hebelwirkung von KI-Anwendungen auf den beiden Ebenen grundlegend unterscheidet:

- Prozessoptimierung auf AM-Ebene (Mikro-Ebene): Hier unterstützt KI primär die Effizienz einzelner, dokumentenintensiver Transaktionen. Durch den Einsatz von Natural Language Processing (NLP) können beispielsweise komplexe Mietvertragsdaten vollautomatisiert ausgelesen (*Lease Abstraction*) und auf Plausibilität geprüft werden (vgl. Adediran et al., 2026, S. 223–224; Zhao et al., 2026, S. 121–122).

- Informationelle Aggregation auf PM-Ebene (Makro-Ebene): Der eigentliche Wertbeitrag entsteht erst, wenn KI-Systeme die unstrukturierten Daten aus einer Vielzahl solcher AM-Einzelfälle portfolioübergreifend aggregieren. Erst diese informationelle Verknüpfung ermöglicht es dem Portfolio-Manager, Klumpenrisiken in Echtzeit zu überwachen, vorausschauende, datenbasierte CAPEX-Szenarien zu berechnen und risikoadjustierte Exit-Entscheidungen auf Basis valider Echtzeitdaten statt auf Basis von Vergangenheitswerten zu treffen (vgl. Chandra, 2025, S. 125–129; Souza et al., 2021, S. 174–176; Viriato, 2019, S. 44, S. 53; für die Rolle der Absorptive Capacity bei der inkrementellen Digitalisierung operativer Prozesse siehe auch Vigren et al., 2022, S. 102).

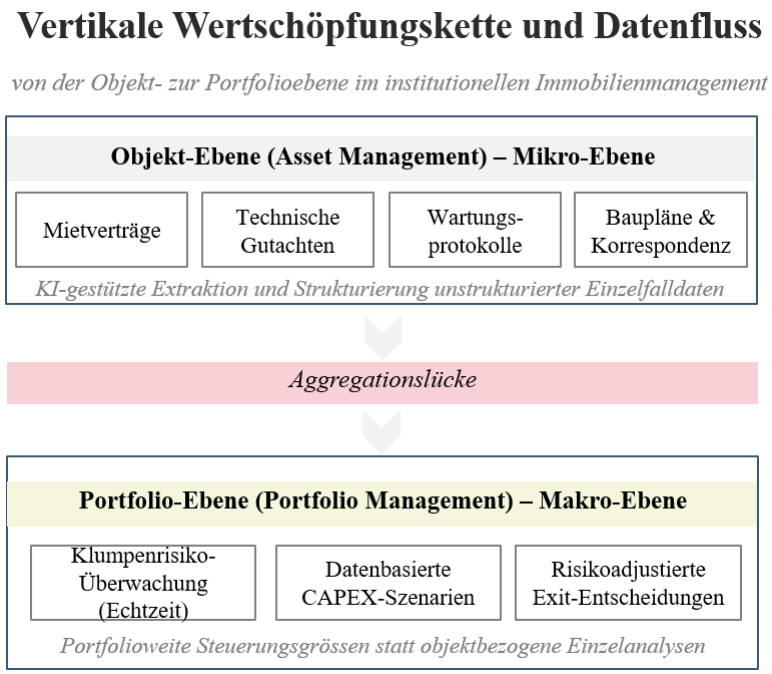


Abbildung 3: Vertikale Wertschöpfungskette und Datenfluss von der Objekt- zur Portfolioebene im institutionellen Immobilienmanagement (eigene Darstellung)

Diese informationelle Brücke von der operativen Objektebene hin zu strategischen Steuerungsgrössen stellt in der heutigen Praxis institutioneller Investoren in der Schweiz die grösste digitale Hürde dar. Die technologischen und prozessualen Barrieren dieses Aggregationsschritts werden in Abschnitt 2.4 vertieft analysiert.

2.2 Informationsökonomie und Transaktionskostentheorie

Die theoretische Verankerung der Forschungsfrage erfolgt über zwei klassische Theorieansätze: die Informationsökonomie und die Transaktionskostentheorie. Beide Ansät-

ze liefern Argumente, warum unstrukturierte Daten in der Immobilienwirtschaft einen unmittelbaren ökonomischen Effekt auf Renditen und Risikopositionen haben.

Die Informationsökonomie geht zurück auf Akerlof (1970), Spence (1973) und Stiglitz (2000) und untersucht die Wirkung asymmetrischer Information auf Marktergebnisse. Akerlofs (1970) berühmtes Markets-for-Lemons-Argument zeigt, dass bei Vorliegen asymmetrischer Information über Qualität die Preisbildung verzerrt wird und in Extremfällen ganze Marktsegmente kollabieren können. Auf Immobilienmärkte übertragen bedeutet dies: Wo Käuferin und Verkäufer oder Asset Manager und Portfolio Manager, einen unterschiedlichen Informationsstand über die Beschaffenheit eines Objektes oder Portfolios haben, entstehen Wohlfahrtsverluste.

Eichholtz, Gugler und Kok (2011) zeigen empirisch, dass eine höhere Transparenz auf Immobilienmärkten zu niedrigeren Risikoprämien und höheren Investitionsvolumina führt (S. 152–153). Im selben Sinne argumentiert der Global Real Estate Transparency Index, dass die transparentesten zehn Prozent der Märkte über 75 Prozent der globalen institutionellen Immobilieninvestitionen auf sich vereinen (vgl. JLL & LaSalle, 2024, S. 6). Die Reduktion von Informationsasymmetrien ist also nicht nur ein operatives, sondern ein strategisches und kapitalmarktrelevantes Anliegen. Auf der Mikro-Ebene des einzelnen Objekts weisen zudem Eichholtz, Holtermans und Yönder (2016, S. 782) nach, dass lokale informationelle Asymmetrien die operative Performance (wie Leerstände und Mietzinserlöse) direkt negativ beeinflussen.

KI-gestützte Analysen unstrukturierter Daten setzen genau an dieser Asymmetrie an. Wenn beispielsweise Tausende von Mietverträgen mittels NLP analysiert werden, ist das Ziel nicht die Detailkenntnis einer einzelnen Kündigungsfrist, sondern die Identifikation portfolioweiter Klumpenrisiken in Bezug auf Vertragslaufzeiten, Branchenexposition oder Indexierungsklauseln. Aus Sicht der Informationsökonomie reduziert dies die Asymmetrie zwischen den operativen Datenhaltern und der strategischen Steuerungsebene und sollte damit ceteris paribus zu einer effizienteren Allokation und einer geringeren Risikoprämie führen.

Die Transaktionskostentheorie nach Coase (1937) und Williamson (1985) liefert den zweiten theoretischen Pfeiler. Coase argumentiert, dass Unternehmen genau dann Aktivitäten internalisieren, wenn die Kosten der Marktnutzung, also Such-, Verhandlungs-, Koordinations- und Kontrollkosten, die internen Organisationskosten übersteigen. Wil-

liamson (1985) verfeinert diese Argumentation entlang der Dimensionen Spezifität der Vermögenswerte, Unsicherheit und Häufigkeit von Transaktionen.

Auf das Portfolio Management übertragen lassen sich die Such- und Aggregationskosten unstrukturierter Daten als zentrale Transaktionskosten interpretieren. Ein Portfolio Manager, der für eine Investitionsentscheidung manuell durch eine Vielzahl von Mietverträgen, Gutachten und Korrespondenzen navigieren muss, verursacht hohe Such- und Verarbeitungskosten. KI-gestützte Anwendungen senken diese Kosten substanziell und verschieben damit die ökonomische Grenze, an der eine Aktivität automatisierbar wird (vgl. Brynjolfsson & McAfee, 2014, S. 91; Agrawal et al., 2018, S. 20). Aus Sicht der Transaktionskostentheorie ist KI also kein blosses Effizienz-Tool, sondern eine strukturverändernde Technologie, welche die Grenze zwischen automatisierbaren und nicht-automatisierbaren Aufgaben verschiebt.

Beide Theorieansätze konvergieren in einer zentralen Aussage: Investitionen in die systematische Erschliessung unstrukturierter Daten haben einen unmittelbaren ökonomischen Effekt auf Portfoliorenditen und Risikoprofile. Sie sind keine reinen Produktivitätsmassnahmen, sondern strategische Investitionen in die Informationsbasis der Anlageentscheidung.

Eine kritische Beobachtung der Literatur betrifft die Differenzierung zwischen technologischer und organisatorischer Reife. Während die technologische Reife einzelner KI-Anwendungen rasch zunimmt, hinken die organisatorischen Strukturen, Prozesse und Governance-Modelle nach. Dies deckt sich mit den von Vigren et al. (2022, S. 98) dokumentierten organisationalen Digitalisierungsbarrieren, die zeigen, dass technologische Verfügbarkeit und organisationale Aufnahmefähigkeit (*Absorptive Capacity*) auseinanderfallen können. Diese Beobachtung ist für die vorliegende Arbeit zentral, weil sie die These stützt, dass der Wettbewerbsvorsprung nicht primär aus dem Zugang zu Technologie, sondern aus der Fähigkeit zur strukturellen Integration entsteht.

Eng mit der informationsökonomischen und transaktionskostentheoretischen Argumentation verknüpft ist die Frage der Governance und Haftung. Wo KI-gestützte Analysen in Anlage- und Steuerungsentscheidungen einfliessen, verändert sich nicht nur die Informationsbasis, sondern auch die Zurechnung von Verantwortung für deren Richtigkeit. Die Literatur zu KI in regulierten, datensensiblen Branchen wie der Versicherungs- und Immobilienwirtschaft identifiziert die mangelnde Interpretierbarkeit vieler KI-Modelle als zentrales Hemmnis: Komplexe Modelle, insbesondere neuronale Netze und

Ensemble-Verfahren, gelten als „Black Box“, deren Entscheidungslogik nicht unmittelbar nachvollziehbar ist. Das ist ein erhebliches Problem in risikosensitiven, regulierten Anwendungsfeldern, in denen Transparenz und Rechenschaftspflicht zentrale Anforderungen sind (Kuppan et al., 2024, S. 181289). Methoden der erklärbaren KI (Explainable AI, XAI) wie SHAP oder LIME werden in der Literatur als technische Antwort auf dieses Problem diskutiert, lösen die zugrunde liegende Governance-Frage jedoch nicht vollständig auf (Kuppan et al., 2024, S. 181290).

Für institutionelle Investoren verschärft sich diese Problematik durch aufsichtsrechtliche Anforderungen an die Nachvollziehbarkeit von Anlageentscheidungen. Kuppan et al. (2024, S. 181290) verweisen darauf, dass Modellgovernance und Rechenschaftspflicht (*„model governance and accountability“*) in regulierten Finanz- und Immobilienkontexten explizit verlangte organisatorische Rahmenwerke voraussetzen, welche die Leistung von KI-Modellen laufend überprüfen. Diese Anforderung korrespondiert mit dem bereits skizzierten Befund, dass technologische Reife und organisationale Aufnahmefähigkeit auseinanderfallen können (vgl. Vigren et al., 2022, S. 98): Eine Organisation kann über leistungsfähige KI-Modelle verfügen, ohne dass die Governance-, Kontroll- und Freigabestrukturen bereitstehen, um deren Resultate verantwortbar in Entscheidungsprozesse einzubetten. Für die vorliegende Arbeit folgt daraus, dass Governance und Haftung nicht als nachgelagerte Implementierungsdetails, sondern als konstitutive Bedingung für die Aggregation KI-gestützter Erkenntnisse zu portfolioweiten Steuerungsgrössen zu behandeln sind. Ob und wie institutionelle Investoren in der Schweiz diese Bedingung erfüllen, wird in Kapitel 3.5.5 empirisch untersucht.

2.3 AI-Entwicklungen in der Immobilienwirtschaft

Die Adoption von KI in der Immobilienwirtschaft ist Gegenstand einer wachsenden Literatur. Einen geeigneten Einstieg bietet die etablierte PropTech-Taxonomie von Baum (2017) und Baum et al. (2020), die in der akademischen, wie in der praxisorientierten Diskussion eine Referenzfunktion einnimmt. Braesemann und Baum (2020, S. 15–18) unterscheiden auf Basis von über 7’000 PropTech-Unternehmen sechs Technologie-Cluster: Smart Real Estate, Data Analytics, Modelling, Real Estate FinTech, Business Processes sowie ConTech. Der Kern der gegenwärtigen Entwicklung, und zugleich Fokus der vorliegenden Arbeit, liegt im Cluster Data Analytics.

Cluster	Beschreibung	Beispiele
Smart Real Estate	Technologien zur operativen Steuerung und Bewirtschaftung von Liegenschaften	Building Management Systems, IoT-Sensorik
Data Analytics	Erhebung, Auswertung und Visualisierung von Immobiliendaten zur Entscheidungsunterstützung	Property-Analytics-Plattformen, Marktdaten-Dashboards
Modelling	Modellierung und Simulation von Immobilienwerten, -risiken und -performance	Automatisierte Bewertungsmodelle (AVM), Risikomodelle
Real Estate FinTech	Plattformen für Transaktionen, Finanzierung und Investitionsvermittlung	Crowdfunding, Tokenisierung
Business Processes	Digitalisierung und Automatisierung interner Geschäftsprozesse	Property-Management-Software, CRM-Systeme
ConTech	Technologien für Planung, Bau und Instandhaltung von Immobilien	BIM, Bausoftware

Tabelle 1: PropTech-Cluster nach Braesemann und Baum (2020)

Braesemann und Baum (2020, S. 15–18) belegen empirisch, dass das Cluster Data Analytics den eigentlichen Kern des Innovationsnetzwerks bildet und mit der Mehrheit der anderen Cluster verbunden ist. Andere Technologien wie Blockchain oder VR/AR seien dagegen periphere Entwicklungen, deren Wertbeitrag bislang spekulativ bleibe. Diese empirische Befundlage stützt die These, dass die zentrale strategische Frage der Branche nicht in der Adoption einzelner Technologien liegt, sondern in der systematischen Nutzung und Aggregation von Daten.

Der konkrete Stand der KI-Adoption in der Immobilienwirtschaft ist heterogen. Tagliaro et al. (2025, S. 12) zeigen in einer mixed-methods-Studie zu Italien und Finnland, dass die Diffusion von PropTech stark von der nationalen Marktstruktur und der Reife institutioneller Akteure abhängt. JLL (2024a, S. 14–15) berichtet auf Basis der Future of Work Survey, dass über 60 Prozent der befragten Unternehmen weltweit bereits KI-Pilotprojekte in Bereichen wie Workplace Strategy, Occupancy Management und Lease Administration durchgeführt haben, wobei die produktive Skalierung deutlich hinterherhinkt. Über 500 Anbieter weltweit offerieren KI-spezifische Lösungen für die Immobilienwirtschaft (vgl. JLL, 2024a, S. 12).

Im Bereich der Vertragsanalyse und Lease Abstraction zeigen Karpook und Wu (2025, S.210) und Zhao et al. (2026, S. 125-128), dass Large Language Models in der Lage sind, Standard-Mietverträge mit hoher Präzision zu strukturieren und kritische Klauseln

(Mietpreis, Kündigungsfristen, Indexierungsklauseln, Optionsrechte) automatisiert zu extrahieren. Kommerzielle Lease-Abstraction-Lösungen erzielen bei Standard-Feldern mittlerweile hohe Genauigkeitsraten (Karpook & Wu, 2025, S. 210). Zhao et al. (2026, S. 125-128) demonstrieren, dass auch komplexere semantische Aufgaben, etwa die Erkennung von Vertragsanomalien oder die Identifikation versteckter Risiken, mit feingetunten LLMs beherrschbar sind. In der Praxis der Transaktionsabwicklung wird jedoch betont, dass der breite produktive Einsatz solcher Systeme an den Schnittstellen erst dann vollzogen wird, wenn die Extraktionsgenauigkeit hoch genug ist, um den strengen Anforderungen der Berufshaftpflichtversicherungen von Rechtsanwälten zu genügen (vgl. Saull et al., 2020, S. 352).

Im Bereich der Bewertungsmodelle haben Deppner et al. (2023, S. 314–315) für den US-amerikanischen Commercial-Real-Estate-Markt mit Daten aus dem NCREIF Property Index gezeigt, dass interpretierbare Machine-Learning-Verfahren (Boosting Trees) die Bewertungsabweichungen gegenüber tatsächlichen Transaktionspreisen substanziell reduzieren können. Die Studie ist insofern bemerkenswert, als sie sich nicht auf reine Vorhersagegenauigkeit, sondern auf die Erklärbarkeit der Modellentscheidungen konzentriert, was für institutionelle Investoren und Regulatoren ein zentraler Aspekt ist.

Im Bereich der prädiktiven Instandhaltung und CAPEX-Planung steht die akademische Literatur in der Immobilienwirtschaft noch am Anfang. Während die Forschung im industriellen Anlagenkontext (Predictive Maintenance) seit Jahren etabliert ist, fehlen bislang systematische empirische Studien zur Übertragbarkeit auf den Immobilienbestand. Praxisorientierte Berichte deuten jedoch auf ein erhebliches Effizienzpotenzial hin, sofern Sensordaten, technische Berichte und Wartungsprotokolle systematisch zusammengeführt werden (vgl. CBRE, 2024, S. 4; Deloitte, 2023, S. 12). Dass diese Technologien zur vorausschauenden Instandhaltung im Rahmen von Smart-Building-Konzepten zu den bedeutendsten strukturellen Entwicklungstreibern im europäischen Immobiliensektor gehören, ist inzwischen auch empirisch belegt (vgl. Pfnür & Wagner, 2020, S. 1009–1010).

Generative KI und insbesondere Large Language Models haben seit etwa 2022 die Adoption neu beschleunigt. McKinsey & Company (2023, S. 5) beziffert das Wertschöpfungspotenzial generativer KI für die Immobilienbranche auf 110 bis 180 Milliarden US-Dollar weltweit. Deloitte (2023, S. 12) berichtet, dass die Stellenanzeigen für generative-KI-Kompetenzen in Immobilienunternehmen zwischen 2022 und 2023 um 64 bzw. 58 Prozent gestiegen sind. JLL und LaSalle (2024, S. 6) weisen zudem darauf

hin, dass die eigene KI-Plattform JLL GPT bereits rund 20 Prozent der globalen Capital-Market-Opportunitäten identifiziert.

Für die vorliegende Arbeit ist die kritische Beobachtung relevant, dass die akademische Literatur zur AI-Nutzung in der Immobilienwirtschaft überwiegend auf der Asset-Ebene angesiedelt ist. Die vorliegende Literatursichtung bestätigt dies: Die überwiegende Mehrheit der begutachteten Beiträge (u.a. Adediran et al., 2026, S. 199; Deppner et al., 2023, S. 314; Karpook & Wu, 2025, S. 210) konzentriert sich auf objektbezogene Anwendungsfälle, während die strategisch-aggregierte Nutzung auf Portfolio-Ebene unterrepräsentiert bleibt. Dieses Muster zeigt sich auch in der Organisationsforschung, wo digitale Initiativen in Immobilienunternehmen mehrheitlich inkrementell und selten portfolioweit angelegt sind (Vigren et al., 2022, S. 102). Die Frage, wie Asset-Daten zu portfolioweiten Steuerungsgrössen aggregiert werden, ist genau jene, die in der vorliegenden Arbeit empirisch untersucht wird.

Bei der Einordnung dieser Befunde ist zwischen der blossen Verfügbarkeit von KI-Anwendungen und ihrem tatsächlichen Realisierungsgrad im Regelbetrieb zu unterscheiden. Studien, die über die «Nutzung» oder «Adoption» von KI berichten, messen diese häufig binär oder auf Basis von Pilotprojekten, ohne den Betriebszustand der jeweiligen Anwendung zu differenzieren (JLL, 2024a, S. 14-15). Diese Unschärfe ist konzeptionell bedeutsam: Ein KI-Anwendungsfall, der als generisches Assistenzsystem eingeführt, aber nicht in einen produktiven, portfolioweiten Entscheidungsprozess mit etablierten Kontrollmechanismen eingebettet ist, unterscheidet sich fundamental von einer Anwendung, die im Regelbetrieb läuft und routinemässig für Steuerungsentscheidungen herangezogen wird. In Anlehnung an die Reifestufenlogik von Brynjolfsson und McAfee (2014, S. 91; vgl. Abschnitt 2.2) lässt sich diese Unterscheidung für die vorliegende Arbeit weiter operationalisieren: Erprobung bezeichnet Absichtserklärungen, Grundlagenarbeit oder generische Assistenzsysteme ohne benannten Anwendungsfall auf Portfolioebene; Pilotierung bezeichnet einen konkret benannten Anwendungsfall, der ausserhalb des Regelbetriebs, etwa in einer Laborumgebung, erprobt wird; punktuelle Integration bezeichnet eine Anwendung, die produktiv läuft und durch etablierte Kontrollmechanismen wie Stichprobenprüfungen und Plausibilisierungsschwellen abgesichert ist. Diese Differenzierung des Use-Case-Realisierungsgrads bildet den analytischen Massstab, anhand dessen die empirischen Befunde in Kapitel 3.5.2 eingeordnet werden.

2.4 Asset- versus Portfolio-Ebene: die Aggregationslücke

Der vorhergehende Abschnitt hat aufgezeigt, dass die KI-Anwendungen auf Asset-Ebene eine respektable Reife erreicht haben. Die zentrale These der vorliegenden Arbeit ist, dass die strategisch entscheidende Aggregationslücke zwischen Asset- und Portfolio-Ebene jedoch weitgehend unbearbeitet bleibt. Diese Aggregationslücke wird in mehreren aktuellen Studien explizit oder implizit thematisiert.

Bereits an dieser Stelle ist eine begriffliche Klärung notwendig, die für den weiteren Argumentationsgang der Arbeit zentral ist. Die Aggregationslücke wird im Folgenden nicht als Verschmelzung von Asset- und Portfolio-Management verstanden, sondern als Fehlen einer Übersetzungsschicht zwischen beiden Ebenen. Asset- und Portfolio-Management bleiben analytisch und organisatorisch unterschiedliche Entscheidungslogiken: Das Asset Management beschreibt und bewirtschaftet reale Objektzustände, während das Portfolio Management auf aggregierten Szenarien, Simulationen und Steuerungsgrössen aufsetzt (vgl. Abschnitt 2.1.3). Die Funktion von KI besteht nicht darin, diese Rollentrennung aufzulösen, sondern granulare, heterogene und teilweise unstrukturierte Objektinformationen in vergleichbare, portfoliofähige Entscheidungsgrundlagen zu überführen. KI wirkt damit als Übersetzungsschicht beziehungsweise Brücke zwischen operativer Objektinformation und strategischer Portfolio-Intelligenz, nicht als Mechanismus, der die fachliche Grenze zwischen den beiden Ebenen nivelliert (Saull & Baum, 2020, S. 4-5; vgl. auch Vigren et al., 2022, S. 103). Diese Präzisierung ist mehr als eine begriffliche Feinheit: Sie verschiebt den Massstab für den Erfolg von KI-Implementierungen weg von der Frage, ob Asset- und Portfolio-Ebene informationell verschmelzen, hin zu der Frage, wie verlässlich, nachvollziehbar und aktuell die Übersetzung zwischen beiden Ebenen erfolgt.

Die deutlichste Formulierung findet sich im Pi-Labs-Oxford-Report 2020 (Saull & Baum, 2020, S. 5, S. 14): Lediglich rund 25 Prozent der untersuchten institutionellen Investmentmanager verfügen demnach über eine etablierte Datenstrategie. Die Autorinnen und Autoren diagnostizieren, dass die dringendste Aufgabe nicht in der Adoption neuer Technologien, sondern in der Strukturierung, Standardisierung und Digitalisierung der bestehenden Datenbasis liege, um Portfolios präzise positionieren zu können. Erst auf dieser Basis könnten alternative Big-Data-Quellen ihren Mehrwert entfalten.

Diese Diagnose deckt sich mit den Befunden von Vigren et al. (2022, S. 98), die als zentrale Hindernisse der Digitalisierung eine konservative Unternehmenskultur, fehlen-

de Kompetenzen sowie unzureichende Anreizstrukturen identifizieren. Ergänzend zeigt die branchenweite Analyse von Tagliaro et al. (2025, S. 12), dass sich das PropTech-Angebot stark auf einzelne Marktsegmente konzentriert und bislang wenig konsolidiert ist. Das ist ein Befund, der auf eine strukturelle Lücke zwischen Angebot und den aggregierten Bedürfnissen von Portfolio-Managern hindeutet.

Auf einer abstrakteren Ebene argumentiert Wainwright (2023, S. 339) in einer kritischen STS-Lesart, dass die digitale Immobilienplattform-Logik die operative Steuerung dominiert, ohne die strategischen Aggregationsfragen ausreichend zu adressieren. Auch Braesemann und Baum (2020, S. 18) betonen, dass die Datenanalyse-Cluster zwar das technologische Zentrum der PropTech-Bewegung bilden, dass aber gerade die institutionellen Eigentümer ihre eigene Datenbasis bislang nur unzureichend strukturieren.

Aus diesen Befunden lässt sich die Aggregationslücke wie folgt präzisieren: Auf Asset-Ebene existieren KI-Anwendungen für die Extraktion und Strukturierung von Informationen aus einzelnen Mietverträgen, Gutachten oder technischen Berichten. Auf Portfolio-Ebene fehlt es jedoch an Architekturen, Prozessen und kulturellen Voraussetzungen, um diese Informationen zu portfolioweiten Steuerungsgrössen zu aggregieren. Drei konkrete Anwendungsfelder sollen diese Lücke illustrieren.

Erstens betrifft die Aggregationslücke die Identifikation von Klumpenrisiken. Ein Portfolio Manager, der wissen möchte, wie viel Prozent seiner Mieteinnahmen aus Branchen mit erhöhter Konjunkturanfälligkeit stammen, müsste theoretisch sämtliche Mietverträge nach Branchen klassifizieren. In der Praxis sind solche Branchen-Tags oft nicht systematisch erfasst, und wenn sie erfasst sind, weichen sie zwischen verschiedenen Property Managern ab. NLP-Verfahren ermöglichen es grundsätzlich, diese Klassifikation automatisiert und konsistenter über das Gesamtportfolio durchzuführen (vgl. Karpook & Wu, 2025, S. 210). Die Fragmentierung der zugrundeliegenden Datenquellen verhindert jedoch in der Praxis die effektive Aggregation.

Zweitens betrifft die Aggregationslücke die vorausschauende CAPEX-Planung. Technische Berichte und Zustandsbeurteilungen liegen typischerweise in Form unstrukturierter PDF-Dokumente vor und enthalten Aussagen zum verbleibenden Lebenszyklus von Bauteilen. Eine systematische Aggregation dieser Aussagen zu einem portfolioweiten CAPEX-Profil über zehn oder zwanzig Jahre ist technisch mit NLP und Computer Vision möglich, wird aber von den meisten institutionellen Investoren nicht systematisch

praktiziert. Die Folge sind reaktive CAPEX-Spitzen, suboptimale Liquiditätsplanung und in Einzelfällen unerwartete Wertkorrekturen.

Drittens betrifft die Aggregationslücke die Risikofrüherkennung über externe Signale. Marktberichte, regulatorische Ankündigungen und Nachrichtenströme enthalten Informationen, die für einzelne Liegenschaften und für das Gesamtportfolio relevant sind. Die Verarbeitung dieser Signale mittels NLP und Sentiment-Analyse ist im Finanzbereich etabliert (Du et al., 2024, S. 12), in der Immobilienwirtschaft jedoch nur bei wenigen institutionellen Akteuren produktiv im Einsatz.

Die These der Aggregationslücke darf dabei nicht überzogen werden. Es gibt erste Anzeichen, dass grosse internationale Investmentmanager (Blackstone, Prologis, CBRE Investment Management) proprietäre Plattformen entwickeln, die den Sprung von Asset zu Portfolio bewältigen (Saull & Baum, 2020, S. 4, S. 12). Die Aussage der vorliegenden Arbeit ist enger gefasst: Bei mittelgrossen institutionellen Investoren in der Schweiz, jener Akteursgruppe, die im empirischen Teil interviewt wird, ist die systematische Aggregation unstrukturierter Daten zu portfolioweiten Steuerungsgrössen institutionell noch nicht verankert. Diese These wird in Kapitel 3 empirisch geprüft.

2.5 Herleitung des Marktvergleichs UK versus Schweiz

Die Wahl des Vereinigten Königreichs als Referenzmarkt für den Transfer von Best Practices ist nicht zufällig, sondern durch mehrere strukturelle Argumente begründet. Erstens nimmt das UK gemäss Global Real Estate Transparency Index 2024 mit einem Score von 1.24 die globale Spitzenposition unter 89 untersuchten Märkten ein, gefolgt von Frankreich (1.26) und den USA (1.34) (JLL & LaSalle, 2024, S. 6). Die Schweiz ist mit einem Score von 1.69 auf Position 14 eingestuft, ein respektabler Platz, aber mit deutlichem Abstand zur Spitzengruppe.

Diese Transparenz-Differenz ist nicht nur ein Ranking-Detail. Der GRETI ist über sechs Subindizes operationalisiert (Investment Performance Measurement, Market Fundamentals, Listed Vehicles Governance, Regulatory and Legal Framework, Transaction Process, Sustainability), die jeweils technologische und Daten-Komponenten umfassen. Die Studienautoren von JLL und LaSalle weisen explizit darauf hin, dass die transparentesten Märkte im 2024-Jahrgang die deutlichsten Fortschritte bei Technologie-Integration und KI-Adoption verzeichnen (JLL & LaSalle, 2024, S. 6). Die zehn transparentesten Märkte vereinten in den letzten zwei Jahren über 1,2 Billionen US-Dollar an direkten

Immobilieninvestitionen und damit über 80 Prozent des globalen Volumens auf sich (vgl. JLL & LaSalle, 2024, S. 6).

Zweitens verfügt das UK über ein PropTech-Ökosystem, das in Europa führend ist. Baum et al. (2020, S. 11-12) zählen rund 800 spezialisierte PropTech-Unternehmen in Grossbritannien. Im Vergleich dazu kommt der Schweizer PropTech-Markt gemäss SwissPropTech (2025, S. 11) auf rund 500 Unternehmen. Diese Grössenordnung bedeutet nicht nur ein quantitatives Gefälle, sondern auch eine deutlich höhere Spezialisierungsdichte und ein reiferes Testfeld für KI-Anwendungen, das über die Pilotphase hinausgewachsen ist.

Drittens ist der UK-Markt durch eine starke institutionelle Prägung gekennzeichnet, die ihn strukturell mit dem Schweizer Markt vergleichbar macht. Beide Märkte werden von Pensionskassen, Versicherungen und Fondsanbietern dominiert, beide weisen einen reifen kotierten Sektor auf, und beide stehen unter wachsendem Druck der ESG-Berichtspflichten. Diese strukturelle Vergleichbarkeit ist eine notwendige Voraussetzung für einen Best-Practice-Transfer. Sie unterscheidet den UK-Schweiz-Vergleich von einem hypothetischen US-Schweiz-Vergleich, der sich an grundlegend unterschiedlichen Marktstrukturen messen lassen müsste.

Indikator	**Vereinigtes Königreich**	**Schweiz**
GRETI 2024 Rang	1 (Score 1.24)	14 (Score 1.69)
PropTech-Unternehmen	ca. 800	ca. 500
Adoptionsquote bei Grossentwicklern	> 65 %	k. A. (deutlich tiefer geschätzt)
Kotierte Immobilienvehikel (Marktwert)	ca. 65.5 Mrd. CHF (~ £ 60 Mrd.)	ca. CHF 70 Mrd.
Marktstruktur	Institutionell geprägt, hoher Anteil REITs	Institutionell geprägt, AGs und Fonds dominant

Tabelle 2: Vergleich zwischen UK und Schweiz nach Schlüsselindikatoren
Quellen: JLL & LaSalle (2024, S. 6); Baum et al. (2020, S. 11-12); SwissPropTech (2025, S. 11); UBS (2024)

Viertens ist der Wissenstransfer zwischen UK und Schweiz organisatorisch erleichtert. Die Royal Institution of Chartered Surveyors (RICS) ist in beiden Ländern aktiv, die wissenschaftlichen Communities (insbesondere die European Real Estate Society und die International Real Estate Society) verbinden britische und Schweizer Forschende, und die Sprache der Branche (Englisch im professionellen Kontext) vereinfacht den Zugang zu UK-Materialien.

Eine wichtige Einschränkung des Vergleichs ist die unterschiedliche regulatorische und kulturelle Umgebung. Der britische Markt ist durch hohe Liquidität, transparente Mietverhältnisse mit standardisierten Leases (Full Repairing and Insuring, FRI Leases) und einen ausgeprägten institutionellen Datenaustausch über Plattformen wie MSCI/IPD geprägt. Der Schweizer Markt arbeitet mit deutlich heterogeneren Mietverträgen, einer stärkeren regulatorischen Steuerung der Mietzinse über das OR (insbesondere Art. 269 ff. OR) und einer fragmentierteren Datenlandschaft. Diese Unterschiede sind beim Best-Practice-Transfer zu berücksichtigen und werden in Kapitel 4 explizit diskutiert.

Eine methodisch wichtige Differenzierung betrifft das Verhältnis zwischen Markttransparenz beziehungsweise Dateninfrastruktur einerseits und tatsächlicher KI-Reife andererseits. Die in diesem Abschnitt herangezogenen Indikatoren (GRETI-Rang, Anzahl PropTech-Unternehmen, volumenkotierte Vehikel) messen in erster Linie die Verfügbarkeit, Standardisierung und Zugänglichkeit von Immobiliendaten sowie die Grösse des Innovationsökosystems. Sie sind damit Indikatoren für einen Infrastrukturvorsprung des UK-Marktes, nicht unmittelbar für einen KI-Reifevorsprung einzelner Organisationen. Der in Abschnitt 2.2 skizzierte Befund zur Diskrepanz zwischen technologischer Verfügbarkeit und organisationaler Aufnahmefähigkeit (Vigren et al., 2022, S. 101-102) legt nahe, dass sich beide Grössen nicht zwangsläufig parallel entwickeln: Ein transparenter, datenreicher Markt schafft günstigere strukturelle Voraussetzungen für KI-gestützte Analysen, garantiert aber nicht, dass einzelne institutionelle Investoren diese Voraussetzungen bereits in produktive, portfolioweite KI-Anwendungen übersetzt haben. Für die vorliegende Arbeit folgt daraus eine methodische Konsequenz: Der Marktvergleich zwischen UK und Schweiz wird in Kapitel 3.6 nicht als Vergleich zweier KI-Reifegrade geführt, sondern als Vergleich der strukturellen Rahmenbedingungen, unter denen sich KI-Reife entwickeln kann. Ob und in welchem Ausmass der britische Infrastrukturvorsprung tatsächlich in einen höheren KI-Reifegrad übersetzt wird, ist eine empirische Frage, die anhand der Interviews in Kapitel 3.6.1 geprüft wird.

2.6 Forschungslücke

Die theoretische Aufarbeitung der Abschnitte 2.1 bis 2.5 lässt sich zu drei Befunden verdichten, aus denen die Forschungslücke der vorliegenden Arbeit präzise abgeleitet werden kann.

Erstens ist die KI-Adoption in der Immobilienwirtschaft auf der operativen Asset-Ebene wissenschaftlich gut dokumentiert. Untersuchungen zu Bewertungsmodellen (Deppner

et al., 2023, S. 314-315), Lease Abstraction (vgl. Karpook & Wu, 2025, S. 210; Zhao et al., 2026, S. 121-122) und Property Management (Vigren et al., 2022, S. 102) liegen vor und zeigen, dass die technologische Reife für viele objektbezogene Anwendungsfälle gegeben ist.

Zweitens ist die Aggregationslücke zwischen Asset- und Portfolio-Ebene als Phänomen erkannt, aber empirisch nur fragmentarisch erforscht. Die Befunde des Pi-Labs-Reports (Saull & Baum, 2020, S. 22), die Befunde von Vigren et al. (2022, S. 98) zu organisationalen Digitalisierungsbarrieren sowie die branchenweite Analyse von Tagliaro et al. (2025, S. 12) zur Fragmentierung des PropTech-Angebots deuten auf ein systematisches Aggregationsdefizit hin, ohne jedoch die spezifischen organisatorischen, technischen und kulturellen Hürden bei mittelgrossen institutionellen Investoren in einer einzelnen Marktumgebung systematisch zu untersuchen.

Drittens fehlen für den Schweizer Markt belastbare empirische Untersuchungen zur Frage, wie institutionelle Investoren KI-Methoden im Portfolio-Management einsetzen und welche Hürden sie bei der Adoption identifizieren. Die wenigen vorhandenen Untersuchungen (SwissPropTech, 2025, S. 11) sind Branchenstudien mit begrenzter methodischer Tiefe und ohne expliziten Fokus auf die Aggregationsproblematik.

Aus diesen drei Befunden ergibt sich die Forschungslücke der vorliegenden Arbeit. Untersucht werden soll, wie institutionelle Immobilieninvestoren in der Schweiz die Aggregationslücke zwischen Asset- und Portfolio-Ebene mittels KI-gestützter Analyse unstrukturierter Daten überbrücken können, und welche Implementierungsstrategien sich aus dem britischen Markt ableiten lassen. Die Arbeit kombiniert damit drei Beiträge: einen theoretischen Beitrag durch die explizite Modellierung der Aggregationslücke, einen empirischen Beitrag durch die Erhebung von Primärdaten in beiden Märkten, und einen praxisbezogenen Beitrag durch die Ableitung konkreter Handlungsempfehlungen.



Abbildung 4: Konzeptioneller Rahmen der Arbeit (eigene Darstellung)

Vier strukturelle Faktoren stabilisieren die Aggregationslücke zusätzlich. Erstens sind IT-Architekturen historisch entlang funktionaler Linien gewachsen (ERP, Property-Management-Systeme, Bewertungsdatenbanken), was dieselbe Information in getrennten Systemen hält (Vigren et al., 2022, S. 102–103). Zweitens liegen bei ausgelagertem Property Management die granularen Bestandsdaten in heterogenen Dienstleistersystemen, deren Standardisierung nur bei anerkanntem strategischem Mehrwert wirtschaftlich vertretbar ist (Saull & Baum, 2020, S. 18). Drittens sind datentechnische Kompetenzen (NLP, Datenmodellierung, ML-Pipelines) gegenüber kaufmännischen und technischen Kompetenzen historisch unterrepräsentiert (Bäcklund et al., 2024, S. 529; Pfnür & Wagner, 2020, S. 1005). Viertens schränkt die aufsichtsrechtlich geprägte Risikokultur institutioneller Investoren den Einsatz nur eingeschränkt erklärbarer KI-Empfehlungssysteme ein: Ein Problem, das Explainable-AI-Ansätze mindern, aber nicht auflösen (Deppner et al., 2023, S. 314–315; Kuppan et al., 2024, S. 181289–181290). Die Aggregationslücke ist damit kein rein technologisches, sondern ein soziotechnisches Phänomen aus IT-Architektur, Outsourcing, Kompetenzprofilen und Risikokultur und eine erfolgreiche Schliessung erfordert entsprechend eine mehrdimensionale Strategie, die in Kapitel 4 auf Basis der empirischen Befunde konkretisiert wird.

Die strukturelle Ähnlichkeit der UK- und Schweizer Märkte zeigt sich auch in der Akteurslandschaft. In beiden Märkten dominieren Pensionskassen, Versicherungen und spezialisierte Investmentmanager das institutionelle Segment, während kotierte Immobiliengesellschaften (im UK als REITs, in der Schweiz als Immobilien-AGs und Anlagestiftungen organisiert) einen erheblichen Anteil des handelbaren Volumens stellen. Auch die Verschuldungsgrade liegen in vergleichbaren Bandbreiten, und die regulatori-

schen Anforderungen an die Eigenmittelunterlegung sind durch die jeweils nationalen Aufsichtsbehörden (FCA in UK, FINMA in der Schweiz) ähnlich strukturiert (UBS, 2024; Swisscanto, 2026, S. 8).

Eine wichtige Differenz besteht im Zugang zu standardisierten Marktdaten. Im UK haben die MSCI/IPD-Plattformen über mehrere Jahrzehnte einen institutionellen Datenpool aufgebaut, der Performance-Benchmarks, Marktentwicklungen und sektorale Vergleiche in einer Granularität bereitstellt, die im Schweizer Markt erst in Teilbereichen erreicht wird. Plattformen wie REIDA für institutionelle Schweizer Investoren oder die Daten von Wüest Partner und IAZI sind etabliert, decken jedoch in Granularität und institutioneller Abdeckung nicht den gleichen Reifegrad ab wie die UK-Pendants (vgl. SwissPropTech, 2025, S. 11; Saull & Baum, 2020, S. 18).

Diese Differenz hat unmittelbare Konsequenzen für die KI-Adoption. Wo standardisierte Performance- und Marktdaten in granularer Form verfügbar sind, lassen sich KI-Modelle für Klumpenrisiken, Mietpreis-Forecasts oder Branchen-Exposures gegen belastbare Vergleichsmuster trainieren und validieren. Wo solche Standards fehlen oder fragmentiert vorliegen, müssen institutionelle Investoren entweder eigene Datenpools aufbauen oder mit höheren Modellunsicherheiten leben. Die UK-Best-Practices in der Datenstandardisierung, insbesondere die RICS-Standards für Bewertungs- und Zustandsberichte, sind insofern nicht nur formale Konventionen, sondern unmittelbare Voraussetzungen für die Skalierbarkeit von KI-Anwendungen.

Ein weiterer wichtiger Unterschied betrifft die Mietvertragsstruktur. Im britischen Geschäftsimmobilienmarkt dominieren Full-Repairing-and-Insuring-Leases (FRI Leases) mit fünf bis zehn Jahren Laufzeit, expliziten Indexierungsklauseln (oft RPI- oder CPI-basiert) und klar definierten Optionsrechten. Diese Standardisierung erleichtert die Anwendung von NLP-Modellen erheblich, weil die Variabilität der Vertragsstrukturen begrenzt ist. Im Schweizer Markt hingegen ist die Heterogenität der Geschäftsmietverträge deutlich höher: Indexierungen folgen unterschiedlichen Regimen (Landesindex der Konsumentenpreise, fixe Stufen, Kombinationen), Optionsrechte sind individuell verhandelt und Sonderkonditionen (Mietzinsausnahmen, Ausbaubeiträge, Staffelmieten) sind häufiger. Diese Heterogenität erschwert das Training generischer NLP-Modelle und verlangt eine grössere Investition in domänenspezifisches Fine-Tuning.

Im Wohnsegment ist die Differenz noch ausgeprägter. Während im UK die Mietverhältnisse weitgehend marktorientiert ausgestaltet sind, unterliegen Schweizer Wohn-

mietverträge dem Mieterschutz nach Art. 269 ff. OR, der die Mietzinsanpassung an formelle Anfechtungsrechte und an Bezugsgrössen wie Hypothekarzinssatz und Teuerung bindet. Die KI-gestützte Analyse von Mietzinsstrukturen, Kündigungsoptionen und Indexierungsklauseln muss diese rechtliche Komplexität abbilden. Das ist ein Anspruch, der für allgemeine Sprachmodelle nicht trivial einzulösen ist und domänenspezifische Anpassungen erfordert.

Trotz dieser Differenzen bleibt der UK-Schweiz-Vergleich tragfähig, weil die strukturellen Gemeinsamkeiten überwiegen und die methodischen Lehren aus dem britischen Markt in adaptierter Form auf den Schweizer Kontext übertragbar sind. Die nachfolgende Empirie wird zeigen, welche Praktiken die Befragten als unmittelbar übertragbar einstufen und wo sie spezifischen Anpassungsbedarf sehen.

3 Empirische Untersuchung

Im vorhergehenden Kapitel wurde die Forschungslücke entlang der Aggregationsproblematik zwischen Asset- und Portfolio-Management hergeleitet. Das vorliegende Kapitel beschreibt die empirische Beantwortung der Forschungsfrage. Abschnitt 3.1 erläutert die Wahl des Forschungsdesigns. Abschnitt 3.2 dokumentiert die Datenerhebung. Abschnitt 3.3 begründet die Auswahl der Interviewpartnerinnen und Interviewpartner. Abschnitt 3.4 beschreibt die Auswertungsmethode. Abschnitt 3.5 präsentiert die Ergebnisse entlang der vier Themenblöcke des Interviewleitfadens und schliesst mit einer Synthese zur Reife des Schweizer Marktes sowie den noch zu ergänzenden UK-Befunden.

3.1 Forschungsdesign und Methodik

Die empirische Untersuchung folgt einem qualitativen, zweistufigen Mixed-Mode-Design. Ausgangspunkt ist die Forschungsfrage, wie institutionelle Immobilieninvestoren in der Schweiz durch den Einsatz Künstlicher Intelligenz im Portfolio-Management effizienter und effektiver werden können und welche Implementierungsstrategien sich aus dem britischen Markt ableiten lassen. Diese Fragestellung zielt nicht primär auf messbare Häufigkeiten, sondern auf Deutungen, Begründungen, organisatorische Voraussetzungen und Grenzen aus Sicht erfahrener Entscheidungsträgerinnen und Entscheidungsträger. Ein standardisiertes quantitatives Verfahren wäre deshalb nur eingeschränkt geeignet gewesen, weil es die im Feld entstehenden Sinnzusammenhänge, beispielsweise die Rolle von Datenqualität, Governance, Akzeptanz oder Kompetenzaufbau, nur vorab definieren, nicht aber explorativ erschliessen könnte.

Die Arbeit stützt sich daher auf leitfadengestützte Experteninterviews als primäre Erhebungsform (Bogner, et al., 2014, S. 23-24). Experteninterviews sind besonders geeignet, wenn nicht Alltagsmeinungen, sondern feldspezifisches Entscheidungs-, Erfahrungs- und Kontextwissen erhoben werden soll (Bogner et al., 2014, S. 15-18). Im vorliegenden Untersuchungsfeld betrifft dies insbesondere Personen mit Einblick in Portfolio-Strategie, Datenarchitektur, Investitionsprozesse, digitale Transformation oder institutionelle Governance. Die qualitative Erhebung ermöglicht es, nicht nur bestehende KI-Anwendungen zu erfassen, sondern auch jene Voraussetzungen zu rekonstruieren, unter denen unstrukturierte Gebäudedaten überhaupt in strategische Portfolioentscheidungen übersetzt werden können.

Das realisierte Design wird bewusst als zweistufiges Mixed-Mode-Design verstanden (Schnell et al., 2018, S. 350). Die erste Stufe besteht aus mündlichen leitfadengestützten Interviews mit institutionellen Akteuren im Schweizer Markt. Sie bildet den empirischen Kern der Arbeit, weil die Schweiz der primäre Untersuchungsmarkt ist. Die zweite Stufe ergänzt diese Primärerhebung durch ein mündliches Gruppeninterview, zwei schriftliche Expertenbefragungen und eine systematische Dokumentenanalyse zur Erschliessung des britischen Vergleichsmarkts. Diese Erweiterung ist nicht als methodischer Notbehelf zu verstehen, sondern als dokumentierte Anpassung des Forschungsdesigns an die realisierte Feldsituation. Gerade weil die UK-Dimension im ursprünglichen Design rein interviewbasiert angelegt war, wird die methodische Anpassung transparent ausgewiesen und in der kritischen Würdigung erneut aufgenommen.

Die Kombination mündlicher und schriftlicher Befragungen ist methodisch begründbar, sofern die Erhebungslogik konsistent bleibt. In den mündlichen Interviews sowie in der schriftlichen Befragung von I10 wurde derselbe inhaltliche Leitfaden mit vier Themenblöcken verwendet. Für die schriftliche Befragung von I9 wurde der Leitfaden formatbedingt gekürzt und auf die für den britischen Vergleichsmarkt zentralen Aspekte fokussiert, namentlich Marktreife, Datenverfügbarkeit und Transferpotenzial. Diese Fokussierung ist bei einem schriftlichen Format ohne Möglichkeit zur Rückfrage sachgerecht, erklärt den geringeren Umfang der Antworten und wird bei der Interpretation berücksichtigt. Während mündliche Interviews eine vertiefende Exploration und spontane Präzisierung erlauben, bieten schriftliche Antworten eine stärker verdichtete, reflektierte Form der Experteneinschätzung. Für den britischen Teil wird diese Form zusätzlich durch Sekundärmaterialien ergänzt, um Aussagen zum Marktumfeld, zu Datenstandards und zur PropTech-Reife breiter abzustützen.

Der Forschungsprozess folgte vier Schritten. Erstens wurde aus dem theoretischen Rahmen ein Interviewleitfaden mit vier Themenblöcken abgeleitet. Zweitens wurden geeignete Interviewpartnerinnen und Interviewpartner nach ihrer fachlichen Nähe zur Forschungsfrage ausgewählt und kontaktiert. Drittens wurden die mündlichen und schriftlichen Erhebungen durchgeführt, dokumentiert und pseudonymisiert. Viertens erfolgte die Auswertung mittels qualitativer Inhaltsanalyse, wobei deduktiv aus der Theorie abgeleitete Kategorien mit induktiv im Material entstandenen Kategorien verbunden wurden. Damit ist das Design darauf ausgerichtet, die theoretisch hergeleitete Aggregationslücke empirisch zu prüfen und zugleich neue, im Material auftretende Implementierungsbedingungen sichtbar zu machen.

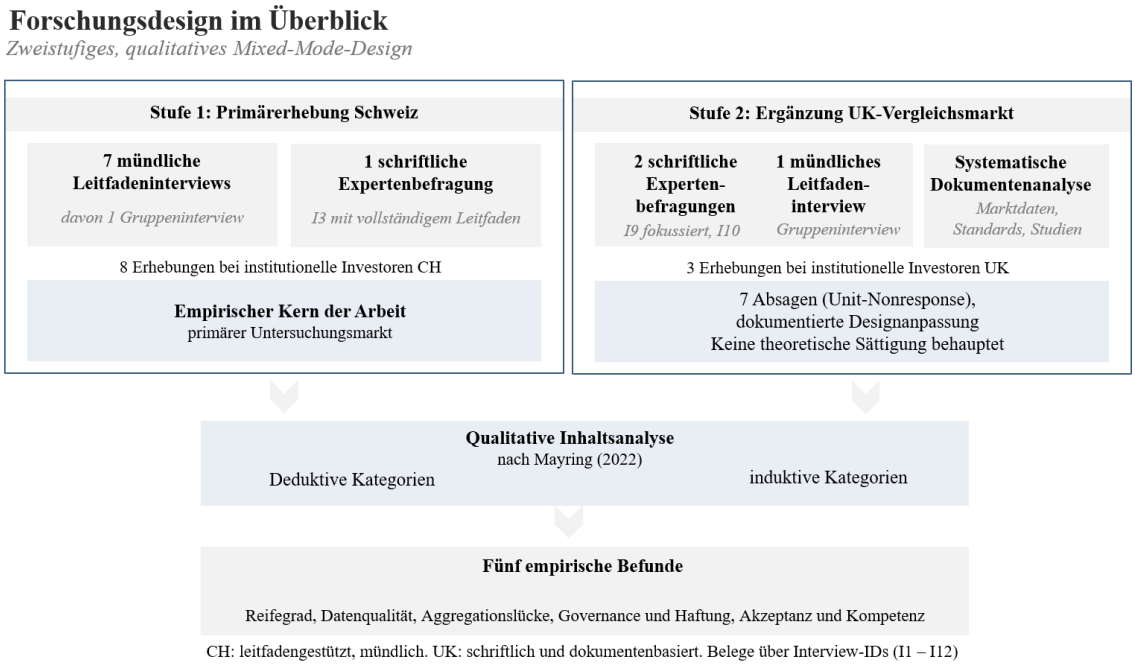


Abbildung 5: Forschungsdesign im Überblick (eigene Darstellung)

3.2 Datenerhebung

Die Akquise der Interviewpartnerinnen und Interviewpartner erfolgte ab dem 01. Mai 2026. Die Erhebungen selbst fanden zwischen dem 03.06.2026 und dem 28.07.2026 statt. Insgesamt wurden dreizehn Personen in elf Erhebungen einbezogen. Acht Erhebungen wurden mündlich durchgeführt, wovon zwei als Gruppeninterviews mit jeweils zwei Teilnehmenden angelegt war. Drei Erhebungen erfolgten schriftlich. Die mündlichen Gespräche fanden persönlich oder per Videokonferenz statt und dauerten zwischen 45 und 120 Minuten. Die schriftlichen Antworten wurden inhaltlich gleichbehandelt, jedoch bei der Interpretation als stärker verdichtete Experteneinschätzungen berücksichtigt.

Der Interviewleitfaden wurde den Befragten vorab zugestellt und umfasste vier Themenblöcke. Themenblock A behandelte die strategische Einordnung und Vision der Nutzung unstrukturierter Daten. Themenblock B fokussierte auf konkrete KI-Methoden, relevante Datentypen und Anwendungsfälle. Themenblock C fragte nach Nutzen, Entscheidungsgüte und Validierung. Themenblock D adressierte Implementierung, organisatorische Hürden und den internationalen Transfer zwischen UK und Schweiz. Die Reihenfolge der Fragen wurde in den mündlichen Interviews flexibel gehandhabt, um auf spezifische Erfahrungsbereiche der Befragten eingehen zu können. Der Leitfaden ist im Anhang dokumentiert.

Die mündlichen Interviews wurden mit Einwilligung sämtlicher Interviewpartner aufgezeichnet und anschliessend transkribiert beziehungsweise stichwortartig verdichtet. Dieses pragmatische Vorgehen folgt den methodischen Empfehlungen des Instituts für die Erstellung von MAS-Abschlussarbeiten (Center for Urban & Real Estate Management [CUREM], 2025, S. 1). Soweit maschinelle Vortranskriptionen verwendet wurden, wurden diese nachbearbeitet, fachlich geprüft und auf Verständlichkeit sowie korrekte Zuordnung der Aussagen kontrolliert. Die Auswertung stützt sich nicht auf wörtliche Zitate, sondern auf sinngemässe Paraphrasen. Dies ist sachgerecht, weil die Gespräche teilweise in mündlicher, dialektaler oder mehrsprachiger Form geführt wurden und für die Forschungsfrage nicht die sprachliche Formulierung, sondern der inhaltliche Gehalt der Expertenaussagen entscheidend ist.

Der Umgang mit Einwilligungen, forschungsethischen Richtlinien und Anonymisierung wurde während der gesamten Erhebungsphase fortlaufend dokumentiert. Um im eng vernetzten institutionellen Schweizer Immobilienmarkt eine lückenlose Vertraulichkeit zu garantieren und gleichzeitig maximale Transparenz über die Qualität des Samples herzustellen, wurde ein differenziertes, zweistufiges Verfahren realisiert.

Erstens haben zahlreiche Interviewpartnerinnen und Interviewpartner eingewilligt, dass ihr Name sowie ihr Unternehmen in der allgemeinen Übersicht im Anhang genannt werden dürfen. Für jene Befragten, die eine vertrauliche Behandlung wünschten, wurde eine konsequente Profil-Anonymisierung vorgenommen. Zweitens wurde die Verknüpfung zwischen den realen Identitäten und den im Ergebnisteil (Kapitel 3.5) verwendeten Interview-IDs (I1 bis I12) vollständig aufgelöst. In der Strukturübersicht (Anhang 2) sind daher weder die im Text genutzten IDs aufgeführt, noch folgt die dortige Auflistung der chronologischen Erhebungsreihenfolge oder der ID-Numerik. Dieses Vorgehen schliesst eine Re-Identifikation von spezifischen Einzelaussagen durch Kombinationsschlüsse systematisch aus.

3.3 Auswahl der Interviewpartner

Die Auswahl der Interviewpartnerinnen und Interviewpartner erfolgte als bewusste Auswahl nach dem Konzentrationsprinzip (Schnell et al., 2018, S. 273–274). Ziel war nicht statistische Repräsentativität, sondern die gezielte Abdeckung jener Akteurstypen und Funktionen, die für die Beantwortung der Forschungsfrage besonders informationsreich sind. Ausgewählt wurden Personen mit Entscheidungs- oder Gestaltungseinfluss auf Portfolioebene, mit Einblick in institutionelle Immobilienanlagen oder mit besonde-

rer Nähe zu Datenstrategie, digitaler Transformation und KI-Anwendungen im Immobilienkontext.

Die angestrebte Stichprobe sollte verschiedene institutionelle Akteurstypen im Schweizer Markt abdecken, insbesondere Versicherungen, Banken, Anlagestiftungen, Immobiliengesellschaften, Asset Manager und Pensionskassen. Zusätzlich war ein Vergleichszugang zum britischen Markt vorgesehen, um die im Theorieteil hergeleitete Referenzfunktion des UK-Markts empirisch zu spiegeln. Die Auswahl folgte damit einer inhaltlichen Logik: Entscheidend war, ob die Befragten Aussagen zur strategischen Nutzung unstrukturierter Gebäudedaten, zur Aggregation auf Portfolioebene und zu Implementierungsbedingungen von KI treffen konnten.

Die realisierte Abdeckung ist für den Schweizer Markt breit, jedoch nicht vollständig. Vertreten sind unter anderem Akteure aus Versicherung, Bank, Anlagestiftung, Immobilien-AG und Asset Management. Pensionskassen im engeren Sinne sind nur indirekt über Anlagestiftungen beziehungsweise institutionelle Anlagevehikel abgebildet. PropTech-Anbieter konnten im realisierten Sample nicht eigenständig berücksichtigt werden. Diese Einschränkung ist relevant, weil Anbieterperspektiven zusätzliche Einsichten zur Marktreife und Skalierbarkeit spezialisierter Lösungen hätten liefern können. Für die Forschungsfrage ist der Fokus auf institutionelle Investoren jedoch vertretbar, da die Arbeit primär deren Portfolioentscheidungen und Implementierungsvoraussetzungen untersucht.

Die UK-Dimension weicht stärker vom angestrebten Design ab. Fünf ab dem 01. Mai 2026 angefragte Kontakte kamen trotz schriftlicher Nachfassvorgänge nicht zustande. Unter den Ausfällen befinden sich UK-Repräsentanten von Unternehmen, die sich in der Schweiz als Interviewpartner zur Verfügung gestellt hatten, sodass auch ein systematischer Zugangsversuch erfolglos verlief. Diese Form von Unit-Nonresponse ist methodisch nicht ungewöhnlich (Schnell et al., 2018, S. 279–286), muss aber offengelegt werden, weil sie die Reichweite der Vergleichsaussagen beeinflusst. Die vier realisierten britischen Datenpunkte stammen zudem aus drei unterschiedlichen Unternehmen, lediglich die beiden schriftlichen Befragungen (I9, I10) entstammen demselben Unternehmenskontext, während das mündliche Gruppeninterview (I11, I12) zwei unabhängige Organisationen abdeckt. Sie werden daher nicht als repräsentatives Bild des britischen Marktes interpretiert, sondern als Experteneinschätzungen, die durch Literatur, Branchenstudien und Dokumentenanalyse ergänzt und eingeordnet werden. Für den

Schweizer Teil ist die empirische Basis deutlich tragfähiger, während für den UK-Teil keine theoretische Sättigung behauptet wird.

Zwei Sonderfälle sind methodisch besonders zu berücksichtigen. Erstens handelt es sich bei I5 um ein Gruppeninterview mit zwei Teilnehmenden aus komplementären Funktionsbereichen sowie I11 und I12 um ein Gruppeninterview mit zwei Teilnehmenden aus unterschiedlichen Unternehmen. Beim Gruppeninterview I5 erhöht sich die inhaltliche Breite der Aussagen, zugleich können einzelne Aussagen nicht immer einer Person eindeutig zugeordnet werden. Zweitens befindet sich I8 zum Erhebungszeitpunkt in einer organisationalen Sondersituation im Zusammenhang mit einer Post-Merger-Integration. Diese Konstellation ist analytisch wertvoll, weil sie Unsicherheit und Offenheit in der KI-Strategie sichtbar macht, gleichzeitig darf sie nicht ohne Weiteres als Normalfall institutioneller Investoren interpretiert werden.

Um die empirische Validität der Arbeit zu untermauern, werden die beteiligten Experten im Anhang namentlich ausgewiesen, sofern hierfür ein ausdrückliches Einverständnis vorliegt. Bei Interviewpartnern ohne Freigabe wird anstelle des Namens ein abstrahiertes, funktionales Rollenprofil aufgeführt. Zur Wahrung der absoluten Vertraulichkeit bezüglich der konkreten inhaltlichen Aussagen wurde jedoch auf jegliche Verknüpfung von Interview-IDs (I1 bis I12) mit dieser Teilnehmerliste verzichtet. Dieses differenzierte forschungsethische Design ermöglicht maximale Transparenz bezüglich der fachlichen Qualität des Samples bei gleichzeitig lückenlosem Schutz der individuellen Aussagen vor einer Re-Identifikation.

Ein zusammenfassendes Profil der Interviewpartnerinnen und Interviewpartner findet sich in Anhang 2. Auf eine zusätzliche Darstellung im Haupttext wird verzichtet, da die Übersicht primär dokumentarischen Charakter hat und keine im Fliesstext dargestellten Zusammenhänge illustriert.

Die Stichprobe erfüllt damit den Anspruch einer theoriegeleiteten, informationsreichen Auswahl, nicht den Anspruch statistischer Verallgemeinerbarkeit. Für den Schweizer Markt kann aufgrund der wiederkehrenden Muster in den Interviews von einer weitgehenden thematischen Verdichtung ausgegangen werden. Für den britischen Markt bleibt die Aussagekraft begrenzter und die empirische Ergänzung dient primär der Plausibilisierung und Kontextualisierung der aus Literatur und Branchenstudien abgeleiteten Vergleichsperspektive.

3.4 Auswertungsmethode

Die Auswertung der Erhebungen erfolgte mittels qualitativer Inhaltsanalyse nach Mayring (2022, S. 84–88). Dieses Verfahren ist geeignet, weil es eine regelgeleitete, nachvollziehbare Verdichtung qualitativen Materials erlaubt und zugleich offen genug bleibt, um neue Kategorien aus dem Material heraus zu entwickeln. Für die vorliegende Arbeit ist diese Verbindung zentral: Einerseits bestehen aus dem Theorieteil bereits klare Vorannahmen, etwa zur Aggregationslücke zwischen Asset- und Portfolioebene, zur Bedeutung unstrukturierter Daten und zur Governance-Problematik. Andererseits zeigten die Interviews zusätzliche Aspekte, die nicht vollständig aus der Literatur ableitbar waren, insbesondere Akzeptanz, Kompetenzaufbau, Haftungslogik und Datenökonomie.

Das Kategoriensystem wurde deduktiv-induktiv aufgebaut. Deduktive Hauptkategorien wurden aus dem theoretischen Rahmen und dem Interviewleitfaden abgeleitet. Dazu gehören insbesondere strategische Einordnung, KI-Methoden und Datentypen, Nutzen und Entscheidungsgüte sowie Implementierung und Transfer. Innerhalb dieser Kategorien wurden während der Materialdurchsicht induktive Subkategorien gebildet, wenn wiederkehrende, theoretisch relevante Muster auftraten. Dazu zählen Datenqualität als bindende Restriktion, KI als Übersetzungsschicht zwischen Asset- und Portfolioebene, Governance und Haftung, Akzeptanz und Kompetenzaufbau sowie die Unterscheidung zwischen experimenteller Nutzung, Pilotierung und punktueller Integration.

Der Codierprozess erfolgte in mehreren Durchgängen. In einem ersten Durchgang wurden die Transkripte und schriftlichen Antworten entlang der deduktiven Kategorien grob erschlossen. In einem zweiten Durchgang wurden wiederkehrende Aussagen verdichtet und mit induktiven Subkategorien versehen. In einem dritten Durchgang wurde geprüft, welche Kategorien ausreichend materialgestützt sind und welche nur als hypothesenbildende Beobachtungen ausgewiesen werden dürfen. Aussagen wurden nicht isoliert gezählt, sondern im Kontext ihrer Begründungslogik interpretiert. Dadurch sollte vermieden werden, dass einzelne pointierte Aussagen ein grösseres empirisches Gewicht erhalten, als ihnen im Gesamtmaterial zukommt. Die Codierung wurde manuell durchgeführt und mittels Einsatz von Copilot validiert, insbesondere auch die Ausarbeitung der zentralen Gütekriterien.

Die Ergebnisdarstellung verwendet durchgehend Interview-IDs (I1 bis I12). Diese Zitierweise wurde gewählt, weil sie einerseits Transparenz über die empirische Grundlage der Befunde schafft und andererseits die Re-Identifikation einzelner Organisationen

erschwert. Namen und Unternehmen dürfen in der Übersicht der Interviewpartner genannt werden, wenn die Interviewpartner dies zugesichert haben, während einzelne Aussagen im Text nicht mit Namen oder Unternehmen verbunden werden. Gerade im institutionellen Immobilienmarkt, in dem Funktionen und Organisationen teilweise leicht zuordenbar sind, ist diese Trennung zwischen Sample-Transparenz und Aussage-Anonymisierung methodisch und forschungsethisch wichtig.

Die Aussagen werden überwiegend paraphrasiert wiedergegeben. Wörtliche Zitate werden bewusst vermieden beziehungsweise nur dort eingesetzt, wo eine ausdrückliche Freigabe vorliegt und die Aussage keine Rückschlüsse auf vertrauliche Organisationsinformationen zulässt. Die Paraphrase erfolgt sinngemäss ohne Veränderung der inhaltlichen Aussage. Dieses Vorgehen trägt der mündlichen Gesprächssituation, sprachlichen Glättungsnotwendigkeiten und den Anonymisierungsauflagen Rechnung. Es ermöglicht zugleich eine wissenschaftlich sachliche Darstellung, die den Fokus auf die analytische Verdichtung statt auf einzelne Formulierungen legt.

Ein Sonderfall betrifft I10. Die dort vorliegenden Antworten sind stärker listenförmig und branchengenerisch formuliert als die übrigen Interviews. Sie werden deshalb nicht als Beleg für die Praxis einer bestimmten Organisation interpretiert, sondern als Experteneinschätzung zur Branchenentwicklung und zum britischen Vergleichsmarkt. Auch I9 und I10 werden im Ergebniskapitel entsprechend zurückhaltend eingesetzt: Sie dienen der Ergänzung und Kontextualisierung, nicht der Ableitung verallgemeinerbarer Aussagen über den UK-Markt insgesamt.

Die nachfolgende Ergebnisdarstellung folgt deshalb nicht strikt der Reihenfolge des Interviewleitfadens, sondern den in der Auswertung entstandenen empirischen Kategorien. Diese Darstellungslogik erhöht die Kohärenz zwischen Methodik und Ergebnispräsentation: Der Leitfaden strukturierte die Erhebung, die Kategorien strukturieren die Analyse. Dadurch können die Befunde nicht nur entlang der gestellten Fragen, sondern entlang der im Material tatsächlich tragenden Erklärungsmuster präsentiert werden.

Deduktive Hauptkategorie	**Grundlage / Fundstelle**
Strategische Einordnung und Vision	Aus Interviewleitfaden Themenblock A abgeleitet, diskutiert in Kap. 3.5.1–3.5.2
KI-Methoden und unstrukturierte Daten	Aus Interviewleitfaden Themenblock B abgeleitet, diskutiert in Kap. 3.5.3

Nutzen und Entscheidungsgüte	Aus Interviewleitfaden Themenblock C abgeleitet, diskutiert in Kap. 3.5.4–3.5.5
Implementierung und internationaler Transfer	Aus Interviewleitfaden Themenblock D abgeleitet, diskutiert in Kap. 3.5.6 und 3.6

Tabelle 3a: Deduktive Hauptkategorien (eigene Darstellung, basierend auf Kap. 3.4)

Induktive Subkategorie	**Kurzbeschreibung**	**Fundstelle / Beispiel-IDs**
Reifegrad-Typologie	Vier Stufen: Erprobung, Pilotierung, punktuelle Integration, Regelbetrieb	Kap. 3.5.2 (I1–I8)
Datenqualität als bindende Restriktion	Vier Problemebenen: Vollständigkeit, Korrektheit, Vergleichbarkeit, maschinelle Verwertbarkeit	Kap. 3.5.3 (I2, I3, I5)
Aggregationslücke / KI als Übersetzungsschicht	Grenze zwischen Asset- und Portfolioebene entlang der Entscheidungslogik, nicht der Datenart	Kap. 3.5.4 (I1, I3)
Governance und Haftung	Einbettung von KI-Ergebnissen in Verantwortlichkeits-, Kontroll- und Freigabesysteme: Human-in-the-Loop	Kap. 3.5.5 (I4, I5, I6, I7, I9, I10)
Akzeptanz und Kompetenzaufbau	Anwenderakzeptanz und Kompetenzentwicklung als eigenständige Implementierungsbedingung neben Daten und Governance	Kap. 3.5.6 (I1)

Tabelle 3b: Induktive Subkategorien (eigene Darstellung, basierend auf Kap. 3.4–3.5)

3.5 Ergebnisse der Experteninterviews

Die Ergebnisdarstellung folgt den fünf empirischen Befunden, die sich aus der Inhaltsanalyse ergeben haben.

3.5.1 Ergebnislogik und Darstellungsweise

Die Auswertung verdichtet die Interviews zu fünf empirischen Befunden. Diese wurden aus wiederkehrenden Aussagen, kontrastierenden Einzelbeispielen und theoretisch relevanten Deutungsmustern abgeleitet. Dabei wird zwischen Aussagen unterschieden, die über nahezu alle Interviews hinweg bestätigt werden, und solchen, die als differenzierende oder hypothesenbildende Beobachtungen einzuordnen sind. Die Belege werden

durchgehend paraphrasiert wiedergegeben und über Interviewkennungen (I1 bis I12) ausgewiesen. Sie illustrieren die Befunde, ersetzen aber nicht die aggregierte Interpretation des Materials. Wo einzelne Befragte Auflagen zur Verwendung ihrer Aussagen gemacht haben, werden diese eingehalten: Betroffene Passagen erscheinen ohne Zuordnung zu Person, Organisation oder Dienstleister. Befunde, die sich ausschliesslich auf eine der acht Schweizer Erhebungen stützen, sind als solche gekennzeichnet, die vier britischen Experteneinschätzungen werden gesondert ausgewiesen.

3.5.2 Reifegrad: Zwischen Experimentieren, Pilotierung und punktueller Integration

Über die acht Schweizer Erhebungen hinweg zeigt sich, dass KI-gestützte Auswertungen unstrukturierter Gebäudedaten bislang nicht als stabiler Regelprozess im institutionellen Portfoliomanagement verankert sind. Die Aussagen verweisen nicht auf einen einheitlichen Entwicklungsstand, sondern lassen sich drei Reifestufen zuordnen. Diese Typologie ist eine analytische Verdichtung des Materials und unterscheidet danach, ob ein konkreter Anwendungsfall auf unstrukturierten Gebäudedaten benannt wird und in welchem Betriebszustand er sich befindet. Als Erprobung gilt, wo Absicht, Grundlagenarbeit oder generische Assistenzsysteme beschrieben werden, ohne dass ein solcher Anwendungsfall benannt wird. Als Pilotierung gilt, wo ein konkreter Anwendungsfall ausserhalb des Regelbetriebs erprobt wird. Als punktuelle Integration gilt, wo eine Anwendung mit etablierten Kontrollmechanismen produktiv läuft.

Der Stufe Erprobung sind sechs der acht Erhebungen zuzuordnen. I4 beschreibt ausdrücklich, man stehe noch ganz am Anfang des Prozesses. I6 verweist auf die Absicht, künftig strategisch mit solchen Daten zu arbeiten, nennt aber zugleich fehlende Plattformen und Grundlagendaten. I8 beschreibt eine Praxis, in der Analysen überwiegend tabellenbasiert erfolgen und spezialisierte Werkzeuge kaum etabliert sind. I2 formuliert, dass Anwendungsfälle in der Portfolioverwaltung derzeit nicht bestehen und KI in bestehenden Strategien nicht offiziell verankert ist. I5 hat generische Assistenzsysteme unternehmensweit eingeführt und schult deren Nutzung, beschreibt den Abgleich zwischen Mietvertragsinhalten und Stammdaten jedoch weiterhin als manuellen Arbeitsaufwand. I3 nimmt eine Sonderstellung ein: Die Erhebung enthält das am weitesten ausgearbeitete strategische Konzept des Samples, benennt aber ausdrücklich, dass KI weder systematisch zur Risikofrüherkennung eingesetzt noch in den Investitions- und

Exit-Entscheidungsrahmen eingebettet ist. Konzeptionelle Klarheit und operativer Reifegrad fallen hier auseinander (I2, I3, I4, I5, I6, I8).

Der Stufe Pilotierung ist I1 zuzuordnen. Dort laufen erste Versuche, ausdrücklich in einer Laborumgebung und nicht im Produktivbetrieb. Als Kernproblem wird die Qualität der bottom-up gelieferten Daten benannt. Zugleich liegen mit der Differenzanalyse zur Bau- und Zonenordnung sowie einem gemeinsam mit einer Hochschule entwickelten Modell zur Mietzinsoptimierung konkrete, benannte Anwendungsfälle vor (I1).

Die Stufe punktuelle Integration ist mit I7 einmal besetzt. Dort läuft eine vollautomatisierte Verarbeitung von Bauzahlungen im Produktivbetrieb, einschliesslich Abgleich mit Verträgen und Zahlungsplänen. Die anfänglich hohe Quote manueller Eingriffe konnte laufend gesenkt werden, flankiert durch Stichproben, Plausibilisierungsschwellen und produktübergreifende Kompetenzzentren. Dieser Fall widerspricht dem Gesamtbefund jedoch nicht, sondern präzisiert ihn: Die Automatisierung setzt auf bereits strukturierten Prozessdaten auf (Verträgen, Zahlungsplänen und definierten Abläufen) und damit gerade nicht auf jenen unstrukturierten Gebäudedaten, deren Erschliessung Gegenstand dieser Arbeit ist (I7).

Die Erprobungs- und Pilotierungsphasen werden in den Interviews durch konkrete organisatorische Mechanismen strukturiert. I1 verweist auf ein konzernweites Jahresziel mit rund 20 Prozent Gewichtung durch die gesamte Hierarchie und jährlicher Rechenschaftspflicht darüber, wo KI eingesetzt wurde. I2 beschreibt ein Assistenzsystem für alle Mitarbeitenden sowie Lernveranstaltungen und Schulungen zur Programmierung von Agenten. I5 hat eine geschäftskonforme Lösung eingekauft und allen Mitarbeitenden lizenziert. I8 ergänzt verpflichtende interne Trainingsmodule mit fachbereichsspezifischen Beispielen zur Promptgestaltung. Diese Mechanismen zeigen, dass Organisationen KI nicht nur technisch erproben, sondern über Zielsysteme, Lizenzierung und Schulung organisatorisch in die Breite tragen, auch dort, wo auf Portfolioebene noch kein Anwendungsfall besteht (I1, I2, I5, I8).

Der Reifegrad ist damit weniger heterogen, als es zunächst erscheint. Die Verteilung ist deutlich zur frühen Stufe hin verschoben: Sechs der acht Erhebungen verbleiben in der Erprobung, eine erreicht die Pilotierung, eine die punktuelle Integration. Die eigentliche Differenz verläuft dabei nicht zwischen den Organisationen, sondern zwischen den Datenarten. Wo Daten bereits strukturiert und Prozesse regelbasiert sind, gelingt produktive Integration. Wo unstrukturierte Gebäudedaten erschlossen werden müssten, domi-

niert Erprobung. Die zentrale Frage verschiebt sich damit von der technischen Einsetzbarkeit hin zu den Bedingungen, unter denen einzelne Anwendungen in wiederholbare, kontrollierte und portfolioweit skalierbare Entscheidungsprozesse überführt werden können.

3.5.3 Datenqualität als bindende Restriktion

Der zweite zentrale Befund betrifft die Datenbasis. Die Interviews verweisen übereinstimmend darauf, dass die zentrale Restriktion nicht primär in der Verfügbarkeit von KI-Methoden liegt, sondern in Qualität, Struktur, Vollständigkeit und Vergleichbarkeit der zugrunde liegenden Daten. Damit verschiebt sich der Fokus der Implementierungsfrage von der Technologie zur organisationalen und prozessualen Datenfähigkeit. Entscheidend ist dabei nicht nur, welche Daten fehlen oder fehlerhaft sind, sondern an welchen Stellen der Datenkette Qualität verloren geht.

Aus dem Material lassen sich vier Problemebenen unterscheiden: Erstens fehlen relevante Daten teilweise vollständig. Zweitens sind vorhandene Daten nicht immer korrekt erfasst. Drittens sind Daten zwischen Systemen, Objekten oder Dienstleistern nicht ohne Weiteres vergleichbar. Viertens liegen viele Informationen zwar vor, sind aber nicht in einer maschinell verwertbaren Struktur verfügbar. Diese Unterscheidung ist eine analytische Ordnung des Materials und wird in den Interviews nicht in dieser Form vorgenommen. Gerade bei Mietverträgen, technischen Berichten und Zustandsdaten zeigt sich jedoch durchgängig, dass die blosse Existenz von Daten noch keine analytische Nutzbarkeit begründet. Datenqualität ist damit weniger als statischer Zustand einzelner Datensätze zu verstehen, sondern als Ergebnis einer mehrstufigen Erfassungs-, Übersetzungs- und Pflegekette.

Die Interviewaussagen verdeutlichen diese Restriktion anhand konkreter Datenprobleme. I1 benennt als Kernproblem, dass die von unten aus den Objekten kommenden Daten für Analysen dieser Art nicht ausreichend verlässlich seien, und illustriert dies an grundlegenden Angaben zu technischen Anlagen: Von einem grossen Teil des Bestands sei weder Alter noch Zustand der Heizungen bekannt. I5 hebt die Diskrepanz zwischen vertraglich vorhandenen und systemseitig verfügbaren Informationen hervor: Nicht alles, was in einem Mietvertrag stehe, sei auch im System erfasst. Der Abgleich verursache erheblichen Arbeitsaufwand, für den bislang kein effizienteres Verfahren gefunden sei. I2 verweist darauf, dass Datenspeicher und Datenstrukturierung derzeit erst aufgebaut und vereinheitlicht würden und man diesbezüglich noch am Anfang stehe. I3 be-

schreibt die Kehrseite unzureichender Datenqualität als Aufwandsproblem: Ein erheblicher Teil der Arbeitszeit hochqualifizierter Fachkräfte fliesse in das Beschaffen, Validieren und Konsolidieren von Daten für wiederkehrende Berichte, wodurch mehr Zeit für die Erstellung als für die Auswertung aufgewendet werde. In einem weiteren Interview wurde dieser Befund besonders deutlich an Beispielen aus dem Vertragsdatenbestand beschrieben: Vertragsenden seien teilweise nicht oder falsch erfasst, und optionale Kündigungs- oder Ausstiegsklauseln würden nicht immer systematisch in den relevanten Systemen abgebildet. Diese Aussage ist inhaltlich zentral, wird hier jedoch bewusst ohne Zuordnung zu einer Person, einer Organisation oder einem Dienstleister paraphrasiert wiedergegeben. Daraus folgt, dass der Einsatz von KI weniger an der Modellierung selbst scheitert als an der vorgelagerten Aufgabe, Daten vollständig, korrekt und vergleichbar bereitzustellen.

Zugleich relativieren die Interviews eine rein mengenorientierte Datafication-Perspektive. Besonders deutlich tritt diese Gegenposition in I1 hervor: Für bessere Entscheidungen sei nicht entscheidend, möglichst viele Daten zu erzeugen, sondern nur jene Daten zu erfassen, die für eine konkrete Entscheidungsfrage tatsächlich benötigt werden. Mehr Daten führten demnach nicht automatisch zu besserer Steuerung. Zudem werde die Kostenwahrheit der Datengenerierung häufig nicht ausreichend berücksichtigt. Diese Position bildet einen Kontrapunkt zur verbreiteten Annahme, dass Wertschöpfung mit wachsendem Datenvolumen zunimmt. Damit rückt neben der Datenverfügbarkeit auch die Frage nach Genauigkeit, Aktualisierungskadenz, Zweckbindung und wirtschaftlicher Rechtfertigung der Datennutzung in den Vordergrund.

Analytisch zeigt sich damit ein Muster von Qualitätsverlusten entlang der Datenkette. Bei I5 liegt der kritische Punkt an der Schnittstelle zwischen Vertragsdokument und System: Informationen entstehen oder verändern sich im operativen Objektmanagement, werden aber nicht immer vollständig, korrekt oder zeitnah in die Systeme überführt. I4 verweist demgegenüber auf die besondere Problematik historischer Daten, deren Herkunft, Struktur und Aktualität nur begrenzt kontrollierbar sind. I1 beschreibt die Schwachstelle grundsätzlicher als Bottom-up-Problem: Wenn die Datenqualität bereits auf Objekt- und Erfassungsebene unzureichend ist, können spätere analytische oder KI-gestützte Verarbeitungsschritte diese Defizite nur begrenzt kompensieren. Die zentrale Ursache liegt daher nicht allein in einzelnen fehlenden Datenfeldern, sondern in der mangelnden Durchgängigkeit zwischen operativer Datenerfassung, systemischer Strukturierung und strategischer Verwertbarkeit.

3.5.4 Die Aggregationslücke zwischen Asset- und Portfolioebene

Die Interviews bestätigen die im Theorieteil hergeleitete Aggregationslücke zwischen objektbezogenen Informationen und strategischer Portfoliosteuerung. Gleichzeitig präzisieren sie diesen Befund: Die Grenze zwischen Asset- und Portfolio-Management verläuft in der Praxis nicht ausschliesslich entlang der Datenart, sondern vor allem entlang der Entscheidungslogik. Während Asset Management näher an der Beschreibung und Bewirtschaftung realer Objektzustände operiert, beginnt Portfoliomanagement dort, wo von realen Zuständen zu Szenarien und Simulationen übergegangen wird (I1). Die in Kapitel 2.1.3 beschriebenen Portfoliofunktionen (Asset Allocation, Risikosteuerung und strategische Diversifikation) setzen auf dieser Unterscheidung auf.

KI wirkt vor diesem Hintergrund nicht als Instrument zur Auflösung der Rollenunterschiede, sondern als Übersetzungsschicht zwischen operativer Objektinformation und strategischer Portfolio-Intelligenz. Ihre Funktion besteht darin, granulare, heterogene und teilweise unstrukturierte Informationen in vergleichbare Entscheidungsgrundlagen zu überführen. Dieser Befund ist insbesondere in I3 ausgeprägt: KI wird dort als Brücke beschrieben, die Informationen aus Verträgen, technischen Berichten, Zustandsdaten und weiteren objektbezogenen Dokumenten in strukturierte Datenpunkte übersetzt und dadurch portfolioweite Vergleiche, frühere Risikoerkennung und wirksamere Priorisierungen ermöglicht. Dadurch kann die Portfoliomanagement-Rolle skalierbarer werden. Die fachliche Trennung zwischen objektbezogener Beurteilung und strategischer Portfolioentscheidung wird dabei nicht aufgehoben, sondern schärfer konturiert (I3).

I1 hebt hervor, dass KI insbesondere dort Mehrwert schafft, wo unstrukturierte Informationen aus Mietverträgen, technischen Unterlagen oder Zustandsberichten nicht nur objektbezogen erschlossen, sondern über den Gesamtbestand hinweg vergleichbar gemacht werden (I1). Technische Berichte, Zustandsdaten und CAPEX-relevante Informationen werden erst durch systematische Extraktion, Strukturierung und Verdichtung für portfolioweite Priorisierungsentscheidungen nutzbar (I3). I7 schärft diese Aggregationslogik anhand eines konkreten Use Case: Dort wird ein externer Partner eingesetzt, um aktuelle Bauvoraussetzungen mit dem eigenen Bestand zu verbinden und das Portfolio auf Entwicklungspotenziale hin zu screenen. Die KI-gestützte Auswertung liefert damit eine erste Grobanalyse. Die weiterführende Beurteilung bleibt jedoch bei fachkundigen Personen (I7). Ergänzend zeigt I7, dass sich die Rolle des Portfolio Managers in solchen Konstellationen verändert: Künftig gewinnt die Fähigkeit an Bedeutung, präzise Fragen zu stellen, geeignete Inputs zu formulieren und die erzeugten Resultate kritisch zu inter-

pretieren. Damit schlägt der Befund eine Brücke zum Kompetenzaufbau in Kapitel 3.5.6. Die Praxis bleibt jedoch heterogen. Während I1 darauf verweist, dass die Grenze zwischen Asset- und Portfoliomanagement insbesondere bei kleineren Produkten personell und organisatorisch nicht immer hart gezogen ist, beschreibt I7 stärker formalisierte Kompetenzzentren. Die im Theorieteil entwickelte Abgrenzung ist daher analytisch hilfreich, findet in der Praxis jedoch kein einheitliches organisatorisches Abbild (I1, I7).

3.5.5 Governance, Kontrolle und Haftung

Ein weiterer zentraler Befund betrifft Governance, Kontrolle und Haftung. Die Interviews zeigen, dass die produktive Nutzung von KI nicht allein von Modellqualität oder Datenverfügbarkeit abhängt. Entscheidend ist vielmehr, ob KI-Ergebnisse in bestehende Verantwortlichkeits-, Kontroll- und Freigabesysteme eingebettet werden können. Solange diese Einbettung ungeklärt bleibt, entsteht kein unmittelbarer Effizienzgewinn, sondern zusätzliche Prüf- und Dokumentationsarbeit.

Am deutlichsten formuliert I4 den zugrunde liegenden Mechanismus. Dort wird auf die persönliche Verantwortung für die Richtigkeit der Berechnungen verwiesen: Berechnungen auf Basis ungeprüfter KI-Eingaben wären ein Verstoss gegen interne Richtlinien. Eine tragfähige Lösung könne nicht teamintern gefunden werden, sondern müsse auf Gruppen- beziehungsweise Unternehmensebene erfolgen. Solange diese fehle, müssten Ergebnisse weiterhin auf herkömmlichem Weg validiert werden, mit der Folge, dass Arbeiten doppelt anfallen, dafür hochqualifiziertes Personal und entsprechende Zeit gebunden werden und der nachweisbare Effizienzgewinn in dieser Phase überschaubar bleibt (I4).

Weitere Aussagen konkretisieren die Prüfnotwendigkeit von der technischen Seite. I5 und I6 verweisen darauf, dass Sprachmodelle Ergebnisse erzeugen können, die inhaltlich falsch sind, ohne dass dies unmittelbar erkennbar wäre. Die Fehlerquelle liege dabei teils im Modell, teils in der Formulierung der Eingabe. I7 beschreibt, wie diesem Risiko im Produktivbetrieb begegnet wird: durch mehrstufige Kontrollmechanismen, Stichprobenprüfungen und im System hinterlegte Plausibilisierungsschwellen. Ausdrücklich benannt wird dabei, dass die Aufsichtsbehörde die Automatisierungsschritte mit Interesse verfolge und es um reale Zahlungsflüsse gehe (I5, I6, I7).

Der Befund reicht über die Ergebniskontrolle hinaus. I1 beschreibt den Grundsatz, keine Sensorik ohne vorgängige Datenschutzrichtlinie zu installieren, da Mieterdaten in weiten Teilen unter besonders schützenswerte Personendaten fielen und in einer allgemei-

nen KI-Auswertung nichts verloren hätten. I3 verweist darauf, dass die kritischsten Hürden nicht technologischer, sondern organisatorischer Natur seien: langsame und sequenzielle Genehmigungsprozesse, ausgeprägte Veränderungsresistenz, eine stark risikoorientierte Grundhaltung sowie Silostrukturen und konkurrierende Budgetansprüche (I1, I3).

Dieser Befund relativiert technologieoptimistische Annahmen. Human-in-the-loop erscheint in den Interviews nicht als Übergangsphänomen, das mit besseren Modellen verschwindet, sondern als strukturelle Voraussetzung verantwortbarer Entscheidungsprozesse: Sie folgt aus der Haftungsordnung, nicht aus mangelndem Vertrauen in die Technik. Die beiden britischen Experteneinschätzungen stützen diese Lesart. I9 hält fest, dass Marktanalysten KI-Ergebnisse ausnahmslos validierten und dafür ein Verständnis des Verfahrens sowie seiner möglichen Fehlerquellen benötigten. I10 formuliert, KI könne die erste Antwort erzeugen, die Verantwortung für die endgültige Antwort verbleibe jedoch bei den Investmentprofis. Erklärbarkeit, Auditierbarkeit und menschliche Aufsicht seien Voraussetzung für die Verwendung in Gremienunterlagen. Diese Aussagen sind als Experteneinschätzungen zur Branchenpraxis zu lesen, nicht als Beleg für die Praxis einer bestimmten Organisation (I9, I10).

3.5.6 Akzeptanz und Kompetenzaufbau

Neben Daten und Governance treten personelle Faktoren als eigenständige Implementierungsbedingungen hervor. Erstens zeigen die Interviews, dass Akzeptanz auf Anwenderebene über Erfolg oder Scheitern technisch funktionsfähiger Lösungen entscheiden kann. Managementunterstützung allein reicht nicht aus, wenn die Lösung nicht in Arbeitsroutinen integriert oder von den betroffenen Mitarbeitenden nicht als hilfreich wahrgenommen wird.

Ein Beispiel aus I1 verdeutlicht dies besonders klar: In einem gemeinsam mit einer Hochschule entwickelten Projekt zur KI-gestützten Optimierung von Mietzinsen war die technische Funktionsfähigkeit gegeben und die Lösung wurde auf Managementebene positiv beurteilt. Die Umsetzung scheiterte gleichwohl, weil die Mitarbeitenden die Arbeit mit dem Werkzeug verweigerten. Das Vorhaben wurde eingestellt (I1). Erfolgreiche Implementierung ist damit weder durch Managemententscheidungen noch durch technische Leistungsfähigkeit hinreichend erklärbar, sondern hängt wesentlich von der Einbindung der Anwenderinnen und Anwender ab. Als Gegenmassnahme beschreibt dieselbe Organisation ein konzernweites Jahresziel mit rund zwanzig Prozent Gewich-

tung über die gesamte Hierarchie, verbunden mit einer jährlichen Rechenschaftspflicht darüber, wo KI eingesetzt wurde. Akzeptanz kann demnach aktiv gesteuert und institutionell verankert werden (I1).

Zweitens verweist das Material auf eine langfristige Kompetenzfrage. I1 beschreibt, dass Einstiegspositionen zunehmend durch KI substituiert würden, während die Beurteilung der Ergebnisse weiterhin erfahrene Fachkräfte erfordere. Offen bleibe, wo diese künftig ausgebildet werden. Auf Nachfrage nach einer Lösung wird ausdrücklich eingeräumt, dass keine vorliege. I4 formuliert unabhängig davon dieselbe Sorge: Wer sich bei jeder Aufgabe auf KI verlasse, bilde jenes Urteilsvermögen nicht aus, das eine verantwortungsvolle Position erfordere. In Grossbritannien und den Vereinigten Staaten sei der Rückgang von Einstiegspositionen bereits sichtbar, für die Schweiz sei die Entwicklung perspektivisch relevant (I1, I4).

Dieser Befund ist empirisch schmaler abgestützt als die Daten- und Governancebefunde. Er gewinnt seine Aussagekraft daraus, dass er in keinem Themenblock des Leitfadens erfragt wurde und in zwei Interviews unabhängig voneinander unaufgefordert vorgebracht wurde. Er wird daher als hypothesenbildende Beobachtung ausgewiesen und im Ausblick als weiterer Forschungsbedarf aufgenommen.

Zwischen diesem und dem vorangehenden Befund besteht ein innerer Zusammenhang. Wenn menschliche Validierung strukturell erforderlich ist und nicht mit besseren Modellen entfällt, dann ist die Verfügbarkeit qualifizierter Prüfender keine Personalfrage, sondern eine Systemvoraussetzung. Die Skalierbarkeit KI-gestützter Portfoliosteuerung wäre damit durch dieselbe Entwicklung begrenzt, die sie ermöglicht.

3.5.7 Verdichtung der empirischen Befunde

Zusammenfassend zeigen die Interviews, dass der Einsatz Künstlicher Intelligenz im institutionellen Immobilien-Portfoliomanagement nicht an einer einzelnen Barriere scheitert. Die Verzögerung entsteht aus dem Zusammenwirken unreifer Datengrundlagen, heterogener Prozesslandschaften, ungeklärter Verantwortlichkeiten, regulatorischer Vorsicht und begrenzter organisationaler Aufnahmefähigkeit. Hinzu tritt ein struktureller Befund: KI löst die Trennung zwischen Asset- und Portfolioebene nicht auf, sondern wirkt als Übersetzungsschicht zwischen beiden. Die Aggregationslücke wird damit nicht überwunden, sondern erstmals bearbeitbar. Die empirischen Ergebnisse stützen insgesamt eine nicht technologiezentrierte Interpretation: KI kann Effizienz und Ent-

scheidungsgüte erhöhen, wenn sie als Bestandteil eines Daten-, Governance- und Kompetenzsystems verstanden wird.

Für den Schweizer Markt ergibt sich ein zur frühen Stufe hin verschobenes Bild. Auf operativer Ebene und in klar abgegrenzten Anwendungsfällen sind einzelne Automatisierungen und Assistenzsysteme sichtbar. Auf Ebene strategischer Portfolioentscheidungen fehlt jedoch überwiegend eine systematische, wiederholbare und governanceseitig abgesicherte Nutzung unstrukturierter Gebäudedaten. Die entscheidende Differenz verläuft dabei nicht zwischen den Organisationen, sondern zwischen den Datenarten: Wo Daten bereits strukturiert und Prozesse regelbasiert sind, gelingt produktive Integration. Wo unstrukturierte Gebäudedaten zu erschliessen wären, dominiert Erprobung. Der britische Vergleichsmarkt wird in Kapitel 3.6 gesondert betrachtet.

3.6 UK-Vergleich und Transferperspektive

Die vorangehende Ergebnisdarstellung hat den Schweizer Markt entlang der fünf empirischen Befunde Reifegrad, Datenqualität, Aggregationslücke, Governance sowie Akzeptanz und Kompetenzaufbau verdichtet. Der UK-Teil wird bewusst als eigenes Kapitel anschliessend an die Schweizer Befunde geführt. Diese Struktur ist methodisch angezeigt, weil die Datengrundlage nicht identisch ist: Während die Schweizer Befunde auf acht Erhebungen mit breiterer Akteursabdeckung beruhen, stützt sich die UK-Perspektive auf ein Doppelinterview sowie schriftliche Experteneinschätzungen und eine ergänzende Dokumenten- und Literaturauswertung. Der UK-Teil erfüllt daher nicht dieselbe Funktion wie Kapitel 3.5. Er dient nicht der eigenständigen Generalisierung des britischen Marktes, sondern der kontextualisierten Spiegelung der Schweizer Befunde an einem Markt, der im Theorieteil als transparenter, datenintensiver und PropTech-reifer Referenzmarkt hergeleitet wurde (Baum et al., 2020, S. 23-24; JLL & LaSalle, 2024, S. 6).

Dieser Zuschnitt ist auch inhaltlich kongruent mit Kapitel 3: Die Schweizer Empirie zeigt keine technologische Verweigerung, sondern eine frühe, daten- und governancegebundene Reifephase. Genau daran schliesst der UK-Vergleich an. Er fragt nicht abstrakt, ob der UK-Markt „weiter“ ist, sondern präzise, welche institutionellen Bedingungen eine schnellere Übersetzung von AI-Experimenten in skalierbare Portfolio Intelligence begünstigen und welche dieser Bedingungen auf Schweizer institutionelle Investoren übertragen werden können.

3.6.1 Marktreife und institutioneller Datenkontext

Der UK-Markt wird in den verfügbaren Quellen übereinstimmend als transparenter und datenreicher beschrieben als viele kontinentaleuropäische Märkte. Der Global Real Estate Transparency Index 2024 weist das Vereinigte Königreich als global führenden Transparenzmarkt aus, während die Schweiz zwar als reifer institutioneller Markt gilt, aber in der Transparenzrangierung deutlich hinter der Spitzengruppe liegt (JLL & LaSalle, 2024, S. 6). Diese Differenz ist für die vorliegende Arbeit nicht als Ranglistenbefund relevant, sondern als strukturelle Voraussetzung für AI-Adoption: Wo Performance-, Transaktions-, Miet- und Researchdaten granularer, häufiger und standardisierter verfügbar sind, können AI-gestützte Analysen schneller validiert und in Investmentprozesse eingebettet werden.

Diese Sekundärbefunde werden durch die britische Experteneinschätzung plausibilisiert. I9 beschreibt die AI-Adoption im britischen Real-Estate-Research und in der Portfolio Strategy als rasch reifend, zugleich aber noch nicht durch ein durchgängiges Branchenstandardmodell geprägt. Besonders hervorgehoben werden Forecasting, Standortentscheidungen und Allokationsanalysen als jene Workflows, in denen AI, NLP oder Advanced Analytics bereits spürbar Nutzen stiften. Damit zeigt sich eine andere Ausgangslage als in den Schweizer Interviews: Während dort der Schwerpunkt auf der Erschliessung und Bereinigung der Datengrundlagen liegt, scheint der UK-Kontext stärker von der Frage geprägt zu sein, wie vorhandene Datenströme in Research-, Forecasting- und Allokationsprozesse integriert werden können (I9).

Der Unterschied ist dennoch nicht absolut. Auch I9 weist darauf hin, dass die Branche noch keine einheitlichen Standards besitzt und dass Real Estate aufgrund lokaler Marktbesonderheiten, heterogener Datenlagen und länderübergreifender Strategien weiterhin strukturelle Datenlücken aufweist. Analytische Erfahrung bleibt daher auch im UK-Markt zentral. Dieses Ergebnis ist für die Forschungsfrage wichtig, weil es eine einfache Modernisierungslogik relativiert: Der UK-Markt erscheint nicht deshalb übertragungsrelevant, weil AI dort menschliche Expertise ersetzt, sondern weil institutionelle Datenökosysteme, Researchroutinen und Markttransparenz offenbar bessere Voraussetzungen schaffen, um menschliche Expertise mit AI-gestützter Vorstrukturierung zu verbinden.

Das mündliche Gruppeninterview mit I11 und I12 konkretisiert diese Relativierung: Objektunterlagen (Gutachten, Verträge, Berichte) bleiben überwiegend in ihrer ur-

sprünglichen Form (PowerPoint, PDF, Word) auf gemeinsamen Laufwerken abgelegt. Ein KI-gestütztes Assistenzsystem erleichtert zwar das Auffinden und Zusammenfassen einzelner Dokumente erheblich, übernimmt jedoch keine automatisierte Übertragung der extrahierten Kennzahlen in die Portfoliomodelle. Deshalb fliessen nur strukturiert erfasste Bewertungsdaten automatisiert in die Portfolioebene ein (I11). Der aus Kapitel 3.5.3 bekannte Befund gilt damit auch im britischen Markt.

3.6.2 Relevante Datenquellen und Research-Integration

Für die britische Vergleichsperspektive ist nicht eine einzelne Datenquelle entscheidend, sondern die Kombination verschiedener Datenebenen. I9 nennt strukturierte Marktdaten, proprietäre Portfoliodaten, Mietvertragsdaten, ESG-Daten, Newsfeeds und alternative Datenquellen als relevant. Besonders alternative Daten gewinnen nach dieser Einschätzung an Gewicht, weil Rechenleistung und Automatisierung ihre Beschaffung und Verarbeitung erleichtern. Daraus ergibt sich ein wichtiges Unterscheidungsmerkmal zur Schweizer Empirie: In Kapitel 3.5 wird Datenqualität vor allem als bindende Restriktion der Objekt- und Systemebene sichtbar, im UK-Kontext tritt stärker die Fähigkeit hervor, unterschiedliche Datenquellen in Research- und Forecastingprozesse zu integrieren. Die wachsende Bedeutung datenanalytischer Technologien im immobilienwirtschaftlichen Kontext ist auch empirisch dokumentiert: Braesemann und Baum (2020, S. 19–20) zeigen anhand einer Analyse von über 7'000 PropTech-Unternehmen, dass datenbezogene Technologien den Kern der PropTech-Entwicklung bilden. Die konkrete Gewichtung von ESG-Daten, Newsfeeds und alternativen Datenquellen im britischen Kontext stützt sich darüber hinaus auf die Experteneinschätzung (I9).

Diese Beobachtung passt zur theoretischen Argumentation aus Kapitel 2.4. Die Aggregationslücke entsteht nicht bereits dadurch, dass Daten unstrukturiert sind. Sie entsteht, wenn objektbezogene Informationen, externe Marktsignale und strategische Entscheidungslogiken nicht in einem gemeinsamen analytischen Rahmen verbunden werden. AI kann hierfür eine Übersetzungsschicht bilden, aber nur dann, wenn die zugrunde liegenden Datenquellen ausreichend zugänglich, vergleichbar und aktualisierbar sind. In einem transparenteren Datenökosystem wie dem der UK kann der Engpass daher tendenziell weiter hinten in der Wertschöpfungskette liegen: Weniger bei der erstmaligen Datenerfassung, stärker bei Modellvalidierung, Interpretation und strategischer Einbettung.

Dass die Aggregationslücke auch in einem reiferen Datenökosystem nicht automatisch verschwindet, illustriert I12 anhand einer Dach-Investorenperspektive mit Engagements

in rund hundert Zielfonds. Für die portfolioweite Sicht wird ein spezialisiertes, geschlossenes Portfoliomanagement-System eingesetzt, das statische Fondsdaten mit Performance- und Objektdaten verbindet. Dieses System ist jedoch nicht mit dem unternehmensweiten KI-Assistenzsystem verknüpft, sodass eine gezielte, prompt-basierte Auswertung über alle Zielfonds hinweg gegenwärtig nicht möglich ist. Die beschriebene Zielarchitektur, wonach wiederkehrende Reporting-Vorlagen künftig automatisiert vorbefüllt werden sollen, verschiebt die Rolle der Analystinnen und Analysten von der Datensammlung hin zur Interpretation der aufbereiteten Informationen (I12). Damit bestätigt sich aus britischer Perspektive, dass der entscheidende Engpass nicht die Datenmenge, sondern die Verbindung getrennter Systeme zu einem gemeinsamen analytischen Rahmen ist.

Für die Schweiz folgt daraus keine unmittelbare Kopie britischer Tools, sondern eine Priorisierung von Datenfähigkeiten. Erstens benötigen institutionelle Investoren eine höhere Aktualisierungskadenz bei zentralen Markt- und Bestandsdaten. Zweitens müssen interne Portfoliodaten so strukturiert werden, dass sie mit externen Markt-, ESG-, Planungs- oder Standortdaten kombinierbar sind. Drittens ist zu klären, welche alternativen Datenquellen tatsächlich entscheidungsrelevant sind und welche lediglich zusätzliche Komplexität erzeugen. Diese Differenzierung ist notwendig, weil Kapitel 3.5 gezeigt hat, dass „mehr Daten“ nicht automatisch bessere Steuerung bedeutet. Vielmehr ist die zweckgebundene, validierbare und wirtschaftlich begründete Datennutzung der entscheidende Faktor.

3.6.3 Entscheidungsintegration und Human-in-the-Loop

Ein zentraler Befund des UK-Vergleichs betrifft die Integration AI-gestützter Erkenntnisse in Entscheidungsprozesse. I9 beschreibt, dass AI-unterstützte Insights zunehmend in Forecastingprozessen und Allokationsanalysen verwendet werden, dass finale Einschätzungen und Marktstrategien jedoch weiterhin ein hohes Mass an menschlichem Input benötigen. Diese Aussage stimmt in ihrer Grundlogik eng mit den Schweizer Befunden überein. Auch dort wird AI nicht als autonomer Entscheidungsträger verstanden, sondern als Instrument, das Informationen schneller strukturiert, Such- und Aggregationskosten reduziert sowie Prüf- und Priorisierungsprozesse vorbereitet.

Der entscheidende Unterschied liegt folglich nicht in der Frage, ob der Mensch weiterhin verantwortlich bleibt. Diese Voraussetzung gilt in beiden Märkten. Der Unterschied liegt eher darin, wie weit AI-gestützte Vorarbeiten bereits in wiederkehrende institutio-

nelle Routinen eingebettet sind. Im UK-Kontext werden Forecasting und Allokation ausdrücklich als Anwendungsfelder genannt, während die Schweizer Interviews eine stärkere Konzentration auf Datenbereinigung, Pilotierung und punktuelle Prozessautomatisierung zeigen. Übertragen auf die Reifegradlogik aus Kapitel 3.5.2 bedeutet dies: Die vorliegenden britischen Experteneinschätzungen deuten darauf hin, dass einzelne Teilprozesse, insbesondere Forecasting und Allokation, näher an einer selektiven Integration liegen, während der Schweizer Markt überwiegend zwischen Erprobung und Pilotierung steht.

Für die Schweizer Praxis ist daraus nicht abzuleiten, dass Investment Committees kurzfristig AI-generierte Empfehlungen übernehmen sollten. Im Gegenteil: Die Interviews in beiden Märkten sprechen für eine kontrollierte, auditierbare Human-in-the-Loop-Logik. AI-Ergebnisse müssen fachlich validiert, methodisch verstanden und in Gremienunterlagen so dokumentiert werden, dass Annahmen, Datenquellen, Modellgrenzen und Verantwortlichkeiten nachvollziehbar bleiben. Gerade in regulierten institutionellen Kontexten kann Produktivität nur dann realisiert werden, wenn Prüf- und Freigabeprozesse nicht nachträglich an AI-Auswertungen angehängt, sondern von Beginn an in die Prozessarchitektur integriert werden.

Ein konkretes Anwendungsbeispiel liefert I11: Vor einer Übergabesitzung mit Klienten liess sich eine Führungsperson mehrere Quartalsberichte und Kundenpräsentationen durch das KI-Assistenzsystem auf zentrale Portfoliorisiken verdichten, um sich rasch in ein nicht selbst betreutes Mandat einzuarbeiten. Die inhaltlichen Ergebnisse hätten sich nach eigener Einschätzung auch ohne KI-Unterstützung ergeben, die Aufbereitung sei jedoch deutlich schneller erfolgt und habe als Ausgangspunkt für die eigene Einordnung gedient. Dieses Beispiel bestätigt die in Kapitel 3.5.5 herausgearbeitete Logik: KI liefert eine erste Verdichtung, die fachliche Bewertung verbleibt jedoch bei der verantwortlichen Person. Zugleich benennen I11 und I12 ein Governance-Risiko, das in den Schweizer Interviews nicht in dieser Deutlichkeit auftritt. Beide beschreiben die Gefahr, dass Mitarbeitende unreflektiert generierte Inhalte übernehmen, ohne über die notwendige fachliche Tiefe zu verfügen, um deren Richtigkeit zu beurteilen. Diese Tendenz berge nicht nur ein Entscheidungsrisiko, sondern auch ein Reputationsrisiko, sofern nach aussen erkennbar unreflektierte KI-Ergebnisse kommuniziert werden. Bemerkenswert ist, dass dieses Risiko nach Einschätzung von I11 nicht auf wenig erfahrene Mitarbeitende beschränkt bleibt: Auch erfahrene Fachpersonen berichten, eigene, instinktiv formulierte Einschätzungen zugunsten einer sprachlich glatteren KI-Version zu verwer-

fen, obwohl die inhaltliche Substanz der ursprünglichen Fassung nicht geringer gewesen sei. Ergänzend verweisen beide auf eine kulturelle Voraussetzung produktiver Nutzung: eine einheitliche Disziplin bei Ablage und Beschriftung von Dokumenten, da KI-Systeme nur solche Informationen zuverlässig verarbeiten können, die konsistent strukturiert und benannt sind (I11, I12).

Diese Anforderung ist auch aufsichtsrechtlich nichts Neues. Schon das Model Risk Management der US-Bankenaufsicht verlangt menschliche Validierung, Erklärbarkeit und Auditierbarkeit als festen Bestandteil des Kontrollrahmens, nicht als Übergangslösung (Board of Governors of the Federal Reserve System & Office of the Comptroller of the Currency, 2011). Neuere Rahmenwerke zur KI-Governance im Finanzsektor, etwa dasjenige der Monetary Authority of Singapore (2024), führen diesen Grundsatz konsequent weiter.

3.6.4 Transferierbare Praktiken aus dem UK-Markt

Aus dem Vergleich lassen sich drei transferierbare Praktiken ableiten. Die erste betrifft die Geschwindigkeit und Frequenz der Datenaktualisierung. I9 empfiehlt ausdrücklich, Preis- und Occupancy-Daten schneller und häufiger verfügbar zu machen, da quartalsweise Daten mit erheblichem Zeitverzug für eine dynamische Steuerung nicht ausreichend seien. Diese Empfehlung ist für Schweizer institutionelle Investoren unmittelbar anschlussfähig. Sie bedeutet nicht, dass sämtliche Daten in Echtzeit erhoben werden müssen. Das verlangt aber eine bewusste Priorisierung: Leerstand, Mietvertragsereignisse, ESG-Kennzahlen, CAPEX-Risiken und marktseitige Indikatoren brauchen eine höhere Aktualität als andere Steuerungsgrössen. Die zweite transferierbare Praktik betrifft die Teamzusammensetzung. I9 rät ausdrücklich davon ab, nur technische Profile einzubeziehen, und empfiehlt stattdessen ein breites Team aus Research, Portfolio Management, Asset Management, IT, Data Governance, Compliance und fachlicher Validierung: Ein Punkt, der sich mit den Schweizer Befunden zu Business-IT-Übersetzung und Kompetenzaufbau deckt. Denn AI-gestützte Portfolio Intelligence entsteht nicht durch die Beschaffung eines Tools, sondern durch die institutionelle Fähigkeit, fachliche Fragestellungen in Datenmodelle zu übersetzen, Ergebnisse kritisch zu prüfen und Entscheidungsprozesse entsprechend anzupassen.

Die dritte transferierbare Praktik betrifft langfristige Ressourcierung. Der Übergang von AI-Experimenten zu skalierbarer Portfolio Intelligence dauert Jahre, kein Pilotprojekt schafft das im Vorbeigehen. Damit bestätigt die UK-Perspektive die in Kapitel 3.5 her-

ausgearbeitete nicht-technologiezentrierte Interpretation: Datenqualität, Governance und Kompetenzentwicklung sind keine Begleitfaktoren, vielmehr sind sie die eigentlichen Skalierungsvoraussetzungen. Für Schweizer Investoren heisst das konkret, dass AI-Adoption auf Portfolioebene in eine explizite Daten- und Governance-Strategie eingebettet werden muss, idealerweise mit Verantwortlichkeiten auf Geschäftsleitungs-, Stiftungsrats- oder Verwaltungsratsebene. Dass der produktive Einsatz digitaler Technologien weniger von der Technologie selbst als von der organisationalen Aufnahmefähigkeit abhängt, ist in der Forschung zur Absorptive Capacity im Immobilien-Ökosystem dokumentiert (Vigren et al., 2022, S. 102). Die organisationalen Reibungen bei der Implementierung digitaler Innovationen wurden zudem in einer longitudinalen Fallstudie herausgearbeitet (vgl. Bäcklund et al., 2024, S. 529).

Eine vierte, konkret quantifizierbare Praktik betrifft die Transaktionsvorbereitung. I11 beschreibt ein Software-Werkzeug, das eingehende Investment-Exposés (Word, PDF oder PowerPoint) automatisiert auf zentrale Kennzahlen auswertet, diese in eine Pipeline-Übersicht überführt und eine erste Einschätzung liefert, ob ein Objekt zur Zielrendite eines Mandats passt. Der Aufwand für diesen ersten Prüfschritt reduziere sich dadurch von rund anderthalb Tagen auf ein bis zwei Stunden. Das System liefert dabei ausdrücklich keine automatisierte Anlageentscheidung, sondern eine strukturierte Grundlage, die weiterhin fachlich geprüft werden muss (I11). Für Schweizer institutionelle Investoren lässt sich unmittelbar etwas lernen: Der grösste Effizienzgewinn entsteht meist schon vor der eigentlichen Entscheidung, in der schnelleren Aufbereitung der zugrunde liegenden Informationen. Diese Übersetzungsfunktion wurde bereits in Kapitel 3.5.4 beschrieben.

3.6.5 Grenzen der Übertragbarkeit

Die Übertragbarkeit britischer Praktiken ist durch strukturelle Unterschiede begrenzt. Ein erster Unterschied liegt in der Mietvertragsstandardisierung und dem regulatorischen Kontext: Britische Gewerbemietverträge folgen oft standardisierten Strukturen wie dem FRI-Lease-Modell (Full Repairing and Insuring), der Schweizer Markt dagegen kennt heterogenere Vertragsstrukturen nach den Bestimmungen des Obligationenrechts (Art. 253 ff. OR). Diese Einordnung beruht auf der fachlichen Beobachtung unterschiedlicher Vertragsstandardisierung. Ein systematischer rechtsvergleichender Nachweis liegt ausserhalb des Rahmens dieser Arbeit. NLP-Modelle, die im UK-

Kontext mit relativ wiederkehrenden Vertragslogiken arbeiten, müssen für Schweizer Vertragsbestände stärker domänenspezifisch angepasst und validiert werden.

Zweitens unterscheiden sich Datenökosysteme und Markttransparenz. Der Nutzen britischer Benchmark- und Researchdaten lässt sich nicht direkt übertragen, wenn Schweizer Datenquellen weniger granular, weniger standardisiert oder stärker proprietär sind.

Drittens unterscheidet sich die organisatorische Risikokultur. Schweizer institutionelle Investoren sind häufig stark governance- und reputationsorientiert, was dazu führen kann, dass die Einführung AI-gestützter Prozesse verlangsamt wird, und zugleich den Druck auf Erklärbarkeit, Auditierbarkeit und Dokumentation erhöht. Das ist keine Schwäche, sondern schlicht eine Bedingung, unter der die Implementierung gelingen muss. Erfolgreicher Transfer bedeutet deshalb nicht, britische Geschwindigkeit zu kopieren: Vielmehr sollte in Betracht gezogen werden, britische Strukturprinzipien in Bezug auf Datenfrequenz, Research-Integration, interdisziplinäre Teams und langfristige Ressourcierung an Schweizer Governance- und Vertragsrealitäten anzupassen.

In der Gesamtwürdigung bestätigt der UK-Vergleich die zentrale These der Arbeit: Wert entsteht im KI-gestützten Portfoliomanagement weniger durch automatisierte Einzelaufgaben als dadurch, dass heterogene, teilweise unstrukturierte Datenbestände in geprüfte, strategisch nutzbare Entscheidungsgrundlagen übersetzt werden. Die britische Referenzperspektive zeigt, dass höhere Markttransparenz und reifere Datenökosysteme diesen Übergang erleichtern können. Ebenso deutlich wird aber, dass menschliche Expertise, Validierung und Governance auch in reiferen Märkten nicht ersetzt werden. Der Transfer auf die Schweiz ist damit selektiv möglich, aber nur unter der Bedingung, dass Datenstrategie, Standardisierung, Verantwortlichkeit und Kompetenzaufbau parallel entwickelt werden.

4 Schlussbetrachtung

Das abschliessende Kapitel fasst die Ergebnisse zusammen, diskutiert ihre Aussagekraft und die Grenzen des methodischen Vorgehens. Abschliessend wird ein Ausblick auf weiteren Forschungsbedarf formuliert.

4.1 Fazit

Die vorliegende Arbeit untersuchte, wie institutionelle Immobilieninvestoren im Portfoliomanagement in der Schweiz durch den Einsatz Künstlicher Intelligenz effizienter und effektiver werden können und welche Implementierungsstrategien sich aus dem UK-Markt ableiten lassen. Ausgangspunkt war die Beobachtung, dass institutionelle Immobilienportfolios über grosse Mengen relevanter Informationen verfügen, diese Informationen jedoch häufig in unstrukturierten oder heterogen strukturierten Datenbeständen gebunden sind. Mietverträge, technische Berichte, Zustandsanalysen, Wartungsprotokolle, ESG-Dokumente, Planungsunterlagen und Marktberichte enthalten Informationen, die für strategische Portfolioentscheidungen wesentlich sein können. Solange diese Informationen aber objektbezogen, manuell, verteilt und nicht vergleichbar vorliegen, bleibt ihr strategischer Nutzen begrenzt (vgl. Saull & Baum, 2020, S. 22).

Der theoretische Teil hat diese Problematik als Aggregationslücke zwischen Asset- und Portfolioebene gefasst. Auf Asset-Ebene existieren zunehmend Anwendungen zur Extraktion, Strukturierung und Plausibilisierung einzelner Datenpunkte. Sein strategischer Wert entfaltet sich aber erst, sobald diese Informationen die Portfolioebene erreichen: Verbunden mit externen Markt- und Risikodaten und eingebettet in die eigentlichen Entscheidungsprozesse. Diese Argumentation wurde informationsökonomisch und transaktionskostentheoretisch fundiert: AI reduziert Such-, Verarbeitungs- und Aggregationskosten, kann Informationsasymmetrien senken und verbessert potenziell die Grundlage risikoadjustierter Anlageentscheidungen (Akerlof, 1970, S. 488-490; Coase, 1937, S. 386-390; Williamson, 1985, S. 15-18).

Die empirische Untersuchung stützt diese theoretische Ausgangslage, präzisiert sie aber in wesentlichen Punkten. Erstens zeigt sich im Schweizer Markt kein einheitlicher Reifegrad, sondern ein zur frühen Stufe hin verschobenes Bild. Sechs der acht Schweizer Erhebungen sind überwiegend der Erprobung zuzuordnen, eine der Pilotierung und eine der punktuellen Integration. Entscheidend ist dabei nicht primär der Unterschied zwischen Organisationen, sondern der Unterschied zwischen Datenarten: Wo Daten bereits

strukturiert und Prozesse regelbasiert sind, gelingt produktive Integration eher. Wo unstrukturierte Gebäudedaten erschlossen und portfolioweit nutzbar gemacht werden müssten, dominiert weiterhin Erprobung.

Zweitens erweist sich Datenqualität als bindende Restriktion. Die Interviews zeigen, dass AI-Anwendungen selten an fehlender technologischer Leistungsfähigkeit allein scheitern. Der eigentliche Engpass liegt in unvollständigen, inkonsistenten, nicht vergleichbaren oder nicht maschinell nutzbaren Daten. Datenqualität ist dabei kein statischer Zustand: Sie entsteht als Ergebnis einer mehrstufigen Erfassungs-, Übersetzungs- und Pflegekette. Fehler oder Lücken auf Objekt- und Systemebene können durch spätere Modelle nur begrenzt kompensiert werden. AI-Adoption im Portfoliomanagement ist damit zuerst ein Datenfähigkeitsproblem und erst in zweiter Linie ein Modellierungsproblem.

Drittens bestätigt die Empirie die Aggregationslücke als sozio-technisches Phänomen. AI hebt die Trennung zwischen Asset- und Portfolio-Management nicht auf. Sie wirkt vielmehr als Übersetzungsschicht zwischen operativer Objektinformation und strategischer Portfoliointelligenz. Gerade dadurch wird die analytische Unterscheidung zwischen beiden Ebenen schärfer. Asset Management bleibt näher an der Beschreibung und Bewirtschaftung realer Objektzustände. Portfolio Management hingegen setzt dort an, wo aus diesen Informationen Szenarien und Priorisierungen werden, die am Ende in Allokationsentscheidungen und Risikoüberwachung münden.

Viertens zeigen die Interviews, dass Governance, Kontrolle und Haftung für produktive AI-Nutzung konstitutiv sind. Human-in-the-loop ist nicht nur ein Übergangsmechanismus aufgrund noch unreifer Modelle, sondern eine strukturelle Voraussetzung verantwortbarer Anlageentscheidungen. In regulierten institutionellen Kontexten müssen AI-Ergebnisse validiert und dokumentiert werden, bevor sie erklärt und freigegeben werden können. Fehlt diese Einbettung, entsteht kein Produktivitätsgewinn, sondern zusätzliche Prüf- und Doppelarbeit. Effektivität verlangt deshalb keine autonome Entscheidung, sondern kontrollierte, nachvollziehbare Entscheidungsunterstützung. Diese strukturelle, und nicht bloss temporäre, Notwendigkeit menschlicher Validierung entspricht der etablierten aufsichtsrechtlichen Praxis des Model Risk Management (Board of Governors & OCC, 2011, S. 3-4) und wird in aktuellen Rahmenwerken zur KI-Governance im Finanzsektor bestätigt (Monetary Authority of Singapore [MAS], 2024, S. 8-10).

Fünftens verweisen die Interviews auf Akzeptanz und Kompetenzaufbau als langfristige Implementierungsbedingungen. Technisch funktionsfähige Lösungen entfalten nur dann Wirkung, wenn Mitarbeitende sie als nützlich akzeptieren, im Arbeitsalltag tatsächlich einsetzen und die Ergebnisse fachlich einordnen können. Gleichzeitig entsteht eine neue Kompetenzlücke: Wenn Einstiegsaufgaben zunehmend automatisiert werden, stellt sich die Frage, wie künftige Senior-Fachkräfte jenes Erfahrungswissen aufbauen, das zur Plausibilisierung AI-gestützter Ergebnisse erforderlich ist. Diese Beobachtung ist empirisch schmaler abgestützt, aber theoretisch relevant und verdient weitere Forschung.

Der UK-Vergleich zeigt schliesslich, dass ein reiferes Daten- und Researchökosystem die Skalierung von AI-Anwendungen erleichtern kann, ohne menschliche Expertise zu ersetzen. Der britische Markt zeichnet sich durch höhere Transparenz und granularere Daten aus, getragen von einer deutlich stärkeren Researchintegration. Diese Reife ist jedoch nicht homogen: Auch britische institutionelle Investoren berichten von manueller Datenübertragung zwischen Objekt- und Portfolioebene sowie von nicht verknüpften Systemwelten, sodass die Aggregationslücke als strukturelles Phänomen bestehen bleibt. Zugleich bestätigt auch die UK-Perspektive, dass Analystenerfahrung, Validierung wie auch Governance weiterhin zentral bleiben. Für die Schweiz zählen deshalb vor allem die dahinterliegenden Strukturprinzipien: höhere Datenfrequnz und Standardisierung, ergänzt durch interdisziplinäre Teams, langfristige Ressourcierung und klare Governance.

Die Forschungsfrage lässt sich damit wie folgt beantworten: Institutionelle Immobilieninvestoren in der Schweiz können durch AI effizienter werden, indem sie manuelle Such-, Erfassungs-, Prüf- und Aggregationsprozesse reduzieren. Wirksamer beziehungsweise effektiver werden sie dort, wo AI unstrukturierte Gebäudedaten in portfolioweite Entscheidungsgrundlagen übersetzt, statt isoliert auf Einzelprozesse zu wirken. Der grösste Hebel liegt folglich in einer besseren Informationsbasis für strategische Entscheidungen, nicht im einzelnen automatisierten Dokument. Ein solches System braucht Datenqualität und Standardisierung als Fundament, dazu Governance, fachlicher Validierung und Kompetenzaufbau.

4.2 Diskussion und kritische Würdigung

Die Ergebnisse stützen die theoretische Erwartung einer Aggregationslücke, modifizieren aber deren Interpretation. Kapitel 2 hat die Lücke zunächst als Differenz zwischen verfügbaren objektbezogenen Daten und fehlender portfolioweiter Nutzung beschrie-

ben. Die empirischen Befunde zeigen nun, dass diese Lücke nicht allein technisch zu erklären ist. Sie entsteht aus dem Zusammenwirken historisch gewachsener IT-Architekturen und externer Dienstleisterstrukturen, heterogener Datenmodelle ohne klare Verantwortlichkeiten sowie regulatorischer Vorsicht bei begrenzter organisationaler Aufnahmefähigkeit. Damit ist die Aggregationslücke weniger ein Softwareproblem als ein Governance- und Organisationsproblem.

Diese Interpretation lässt sich an die PropTech- und Digitalisierungsforschung anschliessen. Studien zur digitalen Transformation der Immobilienwirtschaft zeigen seit längerem, dass zwischen technologischer Verfügbarkeit und ihrer produktiven Nutzung eine eigene Lücke besteht (Baum et al., 2020, S. 4, S. 48; Braesemann & Baum, 2020, S. 19–20; Tagliaro et al., 2025, S. 4-5). Braesemann und Baum (2020, S. 19–20) belegen dies quantitativ anhand von über 7'000 PropTech-Unternehmen, und Tagliaro et al. (2025, S. 12-13) arbeiten die Diskrepanz zwischen Technologieangebot und tatsächlichem Praxisbedarf als zentrale, in Wissenschaft und Praxis bislang unzureichend verstandene Spannung heraus. Die vorliegende Arbeit konkretisiert diesen Befund für institutionelle Schweizer Immobilieninvestoren. Die Interviews zeigen: Wahrgenommen und erprobt wird AI als Technologie durchaus und die produktive Skalierung hängt an Voraussetzungen, die ausserhalb des Modells liegen, konkret an Datenstandards und Prozessen ebenso wie an Rollen, Kontrolllogiken und aufgebauten Kompetenzen.

Gleichzeitig relativieren die Ergebnisse einen verbreiteten technologieoptimistischen Diskurs. AI kann Such- und Verarbeitungskosten senken, aber sie eliminiert weder Unsicherheit noch Verantwortung. Besonders in der Immobilienwirtschaft bleiben Daten unvollständig, lokal geprägt und interpretativ. Der UK-Vergleich verdeutlicht dies: Selbst in einem transparenteren Markt mit granulareren Daten betonen Expertinnen und Experten die Bedeutung menschlicher Validierung. Damit bestätigt sich, dass AI im institutionellen Portfolio Management am ehesten als Entscheidungsvorbereitung verstanden wird, die Entscheidung selbst soll jedoch nicht durch AI erfolgen.

Für die Praxis bedeutet dies, dass Implementierungsstrategien nicht toolzentriert aufgebaut werden sollten. Eine isolierte Beschaffung von Lease-Abstraction-, ESG- oder CAPEX-Tools kann zwar lokale Effizienzgewinne erzeugen, bleibt aber strategisch begrenzt, solange die generierten Informationen nicht mit Portfoliozielen, Risikologik und den bestehenden Reporting- und Investmentprozessen verbunden werden. Umgekehrt kann bereits ein einfacheres technisches Setup erheblichen Wert stiften, wenn Datenflüsse, Verantwortlichkeiten und Validierungsprozesse klar definiert sind. Der Reife-

grad institutioneller AI-Adoption zeigt sich daher kaum an der Komplexität der eingesetzten Modelle. Massgeblich sind vielmehr die Wiederholbarkeit und Erklärbarkeit und der damit erzeugten Informationen und ihrer Nähe zur eigentlichen Entscheidung.

Die Handlungsempfehlungen für Schweizer institutionelle Investoren lassen sich entsprechend in fünf Dimensionen bündeln. Am Anfang steht eine explizite Datenstrategie auf oberster Führungs- oder Aufsichtsebene, die unstrukturierte Gebäudedaten als strategische Ressource definiert. Darauf aufbauend sind Datenstandards und Schnittstellen zu priorisieren, insbesondere für Mietverträge, technische Zustandsinformationen, ESG-Daten und CAPEX-relevante Dokumente. AI-Use-Cases wiederum sollten nicht abstrakt, sondern entlang konkreter Entscheidungsprobleme entwickelt werden, etwa Klumpenrisiken, Entwicklungsreserven, Exit-Planung, Sanierungspriorisierung oder regulatorisches Reporting. Ebenso wichtig ist die Ausgestaltung von Human-in-the-loop-Prozessen mit Auditierbarkeit, Plausibilisierungsschwellen und dokumentierter Verantwortung. Und schliesslich braucht es systematischen Kompetenzaufbau, der Fachwissen im Immobilieninvestment mit Daten-, Modell- und Governancekompetenz verbindet.

Die Übertragung britischer Best Practices ist selektiv möglich. Datenfrequenz, Researchintegration, interdisziplinäre Teams und langfristige Ressourcierung sind konzeptionell gut übertragbar. Weniger direkt übertragbar sind konkrete Vertragsanalysemodelle, Datenplattformen oder Benchmarklogiken, soweit sie auf britischen Marktstandards, Lease-Strukturen oder Datenökosystemen beruhen. Der Schweizer Markt benötigt daher keine Imitation des UK-Modells. Gefragt ist eine adaptierte Adoptionsstrategie, die britische Strukturvorteile als Orientierung nutzt, zugleich aber den Schweizer Besonderheiten Rechnung trägt, insbesondere im Mietrecht, in der fragmentierten Datenlandschaft, in der Governancekultur und in der Anbieterlandschaft.

Die Arbeit weist mehrere Limitationen auf. Die qualitative Stichprobe erlaubt keine statistische Verallgemeinerung. Sie ist auf informationsreiche Fälle ausgelegt und ermöglicht analytische, nicht repräsentative Schlussfolgerungen. Des Weiteren ist die UK-Datenbasis begrenzter als ursprünglich geplant. Die britischen Experteneinschätzungen sind wertvoll, für einen repräsentativen Querschnitt des UK-Marktes reichen sie hingegen nicht aus. Zudem beruhen die Ergebnisse auf einem dynamischen Untersuchungsfeld. Gerade generative AI entwickelt sich so schnell, dass Befunde zur Reife einzelner Anwendungen zeitlich sensibel sind. Ein weiterer Punkt ist, dass die Analyse auf institutionelle Investoren fokussiert. PropTech-Anbieter, Property Manager und re-

gulatorische Akteure werden nur indirekt erfasst. Letztlich ist die Codierung durch eine einzelne Verfasserin gegenüber Intercoder-Reliabilität limitiert, auch wenn regelgeleitete Inhaltsanalyse, transparente Kategorienbildung und Reflexion mit dem Betreuer zur Nachvollziehbarkeit beitragen.

Trotz dieser Einschränkungen leistet die Arbeit einen Beitrag auf drei Ebenen. Theoretisch schärft sie die Aggregationslücke zwischen Asset- und Portfolioebene als soziotechnisches Phänomen. Empirisch liefert sie explorative Befunde dazu, wie Schweizer institutionelle Immobilieninvestoren AI derzeit einschätzen, erproben und begrenzen. Praxisbezogen zeigt sie, dass der Übergang zu AI-gestützter Portfolio Intelligence nicht mit einem einzelnen Technologieentscheid beginnt. Am Anfang steht die strategische Arbeit an Datenqualität, Governance und Kompetenz. Damit verschiebt die Arbeit den Fokus von der Frage, ob AI im Immobilienportfoliomanagement eingesetzt werden kann, zu einer entscheidenderen Frage: Unter welchen institutionellen Bedingungen wird dieser Einsatz verantwortbar und skalierbar, und schafft er tatsächlich Wert?

4.3 Ausblick

Aus wissenschaftlicher Perspektive eröffnet die Arbeit mehrere Anschlussfragen. Eine quantitative Folgestudie, welche die in dieser Arbeit qualitativ hergeleitete Reifegradlogik auf eine breitere Stichprobe institutioneller Investoren in der Schweiz und in benachbarten DACH-Märkten überträgt, würde sich anbieten. So könnte geprüft werden, wie weit Datenqualität und Governance auf der einen sowie Human-in-the-loop-Prozesse und Kompetenzaufbau auf der anderen Seite statistisch mit der produktiven Nutzung von AI-Anwendungen im Portfoliomanagement zusammenhängen. Damit liesse sich die explorative Typologie aus Kapitel 3.5 empirisch breiter validieren.

Zusätzlich besteht weiterer Forschungsbedarf zur Validierung AI-gestützter Entscheidungsvorbereitung in regulierten Anlagekontexten. Die vorliegende Arbeit zeigt, dass menschliche Freigabe, Erklärbarkeit und Auditierbarkeit deutlich über einen administrativen Zusatz hinausgehen. Sie bilden die Kernbedingung institutioneller Adoptionsfähigkeit. Künftige Forschung könnte untersuchen, welche Anforderungen Aufsichtsorgane, Investment Committees und Revisionsstellen an die Nachvollziehbarkeit AI-gestützter Analysen stellen und wie diese Anforderungen in Governance- und Dokumentationsprozesse übersetzt werden können.

Weiter sollte die Kompetenzfrage vertieft untersucht werden. Wenn AI repetitive Einstiegsaufgaben reduziert, entsteht langfristig die Gefahr, dass weniger Gelegenheiten zum Aufbau fachlicher Urteilskraft bestehen. Gerade im Immobilieninvestment ist dieses Urteil zentral: Modelle können lokale Marktkenntnis, Vertragsverständnis und Risikoeinschätzung nicht vollständig ersetzen. Die Frage, wie Junior-Profile künftig ausgebildet werden müssen, damit sie AI-Ergebnisse später verantwortungsvoll validieren können, reicht über die Personalpolitik hinaus und tangiert das System umfassend.

Für die Praxis ergibt sich daraus eine klare Prioritätensetzung. Für Schweizer institutionelle Investoren empfiehlt sich, AI-Adoption als langfristiges Transformationsprogramm zu verstehen, nicht als einmaliges Technologieprojekt. Am Anfang steht dabei weniger die Wahl des leistungsfähigsten Modells als die Klärung der entscheidungsrelevanten Fragen: Welche unstrukturierten Daten beeinflussen tatsächlich Portfolioentscheidungen? Welche Daten müssen hierfür standardisiert, aktualisiert und mit externen Quellen verbunden werden? Wer trägt fachlich, technisch und governance-seitig Verantwortung? Und wie werden Mitarbeitende befähigt, AI-Ergebnisse kritisch zu nutzen statt unreflektiert zu übernehmen?

In den nächsten Jahren dürfte der Handlungsdruck weiter zunehmen. Generative AI senkt die Kosten der Informationserschliessung und erhöht die Geschwindigkeit, mit der Datenbestände analysierbar werden. Zugleich wachsen ESG-, Transparenz- und Reportinganforderungen, wodurch die Fähigkeit zur strukturierten Auswertung heterogener Gebäudedaten nach Einschätzung der Verfasserin stärker zum Wettbewerbsfaktor werden dürfte. Ein früher Aufbau belastbarer Datenarchitekturen, klarer Governance und interdisziplinärer Kompetenzen könnte institutionellen Investoren einen Informationsvorsprung verschaffen, während ein rein punktueller Einsatz von AI als Effizienztool das Risiko birgt, dass der strategische Wert der generierten Informationen ungenutzt bleibt.

Der zentrale Ausblick dieser Arbeit lautet daher: Die nächste Entwicklungsstufe des AI-Einsatzes im institutionellen Immobilien-Portfoliomanagement dürfte weniger von vollständig autonomen Anlageentscheidungen geprägt sein als von besseren, schnelleren und nachvollziehbareren Entscheidungsgrundlagen. Wer die Aggregationslücke schliessen will, muss AI als Teil einer institutionellen Informationsarchitektur verstehen. Technologischer Fortschritt allein genügt dafür nicht. Massgeblich bleibt, ob Organisationen Datenqualität und Marktverständnis mit Governance und menschliche Urteilskraft systematisch verbinden.

Literaturverzeichnis

Adediran, A. O., Mohd Aini, A. & Ajibade, S. M. (2026). Adoption of artificial intelligence in property management transactions: a systematic review and trend analysis. *Property Management*, 44(2), 199–231. Gefunden unter https://doi.org/10.1108/PM-02-2025-0007

Anson, M. J. P. (2012). *Handbook of Alternative Assets* (2. Aufl.). Hoboken, NJ: John Wiley & Sons.

Agrawal, A., Gans, J. & Goldfarb, A. (2018). *Prediction Machines: The Simple Economics of Artificial Intelligence*. Boston: Harvard Business Review Press.

Akerlof, G. A. (1970). The Market for "Lemons": Quality Uncertainty and the Market Mechanism. *The Quarterly Journal of Economics*, 84(3), 488–500. Gefunden unter https://www.jstor.org/stable/1879431

Bäcklund, K., Vigren, O. & Carlsson, J. (2024). Implementing digital innovations: Overcoming organizational challenges. *Developments in the Built Environment*, 18, 100436. Gefunden unter https://doi.org/10.1016/j.dibe.2024.100436

Baum, A. (2017). *PropTech 3.0: The Future of Real Estate*. Research Report. Saïd Business School, University of Oxford. Gefunden unter https://www.sbs.ox.ac.uk/sites/default/files/2018-07/PropTech3.0.pdf

Baum, A., Saull, A. & Braesemann, F. (2020). *PropTech 2020: The Future of Real Estate.* Oxford: Saïd Business School, University of Oxford. Gefunden unter https://www.sbs.ox.ac.uk/sites/default/files/2020-02/proptech2020.pdf

Board of Governors of the Federal Reserve System & Office of the Comptroller of the Currency. (2011). *Supervisory Guidance on Model Risk Management* (SR Letter 11-7 / OCC Bulletin 2011-12). Washington, D.C.: Federal Reserve.

Bogner, A., Littig, B. & Menz, W. (2014). *Interviews mit Experten: Eine praxisorientierte Einführung.* Wiesbaden: Springer VS.

Braesemann, F. & Baum, A. (2020). PropTech: Turning Real Estate Into a Data-Driven Market? *SSRN Electronic Journal*. Gefunden unter https://doi.org/10.2139/ssrn.3607238

Brynjolfsson, E. & McAfee, A. (2014). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. New York: W. W. Norton.

Bundesamt für Statistik (BFS). (2026). *Pensionskassenstatistik 2024: Definitive Ergebnisse und Kennzahlen*. Medienmitteilung vom 21. Januar 2026. Neuchâtel: BFS. Gefunden unter https://www.bfs.admin.ch/bfs/de/home.assetdetail.36333466.html

CBRE. (2024). *How AI is Advancing Decision-Making in Corporate Real Estate*. CBRE Insights. Gefunden unter https://www.cbre.com/insights/viewpoints/how-ai-is-advancing-decision-making-in-corporate-real-estate

Center for Urban & Real Estate Management (CUREM). (2025). *Merkblatt zu der Methode „Befragung/Interview" in Abschlussarbeiten im MAS UZH Real Estate*. Zürich: Center for Urban & Real Estate Management, Universität Zürich.

Chambers, D. R., Anson, M. J. P., Black, K. H. & Kazemi, H. B. (2020). *Alternative Investments: CAIA Level I* (4. Aufl.). Hoboken, NJ: John Wiley & Sons.

Chandra, L. (2025). *AI Innovation in Real Estate*. Cham: Springer Nature Switzerland. Gefunden unter https://doi.org/10.1007/978-3-031-93591-6

Coase, R. H. (1937). The Nature of the Firm. *Economica*, 4(16), 386–405. Gefunden unter https://doi.org/10.1111/j.1468-0335.1937.tb00002.x

Davidson, J., Kloess, S. & Steffen, D. (2023). Nachhaltigkeit spaltet institutionelle Anleger. *Die Volkswirtschaft: Plattform für Wirtschaftspolitik*, (3), 48–50. Gefunden unter https://dievolkswirtschaft.ch/de/2023/03/nachhaltigkeit-spaltet-institutionelle-anleger/

Deloitte. (2023). *RE-generative AI: How Technology Can Transform Commercial Real Estate.* Deloitte Center for Financial Services. Gefunden unter https://www.deloitte.com/us/en/insights/industry/financial-services/generative-ai-in-real-estate-benefits.html

Deppner, J., von Ahlefeldt-Dehn, B., Beracha, E. & Schaefers, W. (2023). Boosting the accuracy of commercial real estate appraisals: An interpretable machine learning approach. *The Journal of Real Estate Finance and Economics*, 71(2), 314–351. Gefunden unter https://doi.org/10.1007/s11146-023-09944-1

Du, K., Xing, F., Mao, R. & Cambria, E. (2024). Financial sentiment analysis: Techniques and applications. *ACM Computing Surveys*, 56(9), 1–42. Gefunden unter https://doi.org/10.1145/3649451

Eichholtz, P., Gugler, N. & Kok, N. (2011). Transparency, integration, and the cost of international real estate investments. *The Journal of Real Estate Finance and Economics*, 43(1–2), 152–173. Gefunden unter https://doi.org/10.1007/s11146-010-9244-5

Eichholtz, P., Holtermans, R. & Yönder, E. (2016). The economic effects of owner distance and local property management in US office markets. *Journal of Economic Geography*, 16(4), 781–803. Gefunden unter https://doi.org/10.1093/jeg/lbv018

Gesellschaft für Immobilienwirtschaftliche Forschung (gif) e.V. (2004). *Definition und Leistungskatalog Real Estate Investment Management*. Wiesbaden: gif-Eigenverlag.

Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. Cambridge, MA: MIT Press.

IBM. (2015). *Bringing big data to the enterprise: What is big data?* White Paper. Armonk, NY: IBM Corporation. Gefunden unter https://www.ibm.com/big-data/us/en/

Institut für Finanzdienstleistungen Zug (HSLU). (2025). *Real Estate Investment und Asset Management in der Schweiz 2025: Studienergebnisse*. Rotkreuz: Hochschule Luzern. Gefunden unter https://www.hslu.ch/de-ch/hochschule-luzern/ueber-uns/medien/medienmitteilungen/2025/11/05/ifz-immobilienanlagen-2025/

JLL. (2024a). *Artificial Intelligence: Implications for Real Estate*. JLL Research. Gefunden unter https://www.jll.com/en-us/insights/artificial-intelligence-and-its-implications-for-real-estate

JLL. (2024b). *Schweizer Immobilien-Anlagemarkt: Institutionelle Befragung 2024*. Zürich: Jones Lang LaSalle AG. Gefunden unter https://www.jll.ch/de/trends-and-insights/research/swiss-real-estate-investment-market

JLL & LaSalle. (2024). *Global Real Estate Transparency Index 2024. Research Report. Chicago*: Jones Lang LaSalle IP, Inc. Gefunden unter https://www.jll.com/en-us/insights/global-real-estate-transparency-index

Jurafsky, D. & Martin, J. H. (2026). *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models* (3. Aufl., Entwurf). Stanford University. Gefunden unter https://web.stanford.edu/~jurafsky/slp3/

Kämpf-Dern, A. (2009). *Immobilienwirtschaftliche Managementebenen und -aufgaben: Definitions- und Leistungskatalog des Immobilienmanagements* (Arbeitspapiere zur immobilienwirtschaftlichen Forschung und Praxis, Nr. 15). Technische Universität Darmstadt, Fachgebiet Immobilienwirtschaft und Baubetriebswirtschaftslehre.

Karpook, D. & Wu, P. (2025). Driving progress in corporate real estate with artificial intelligence and machine learning. *Corporate Real Estate Journal*, *14*(3), 210–221. Gefunden unter https://doi.org/10.69554/TQFL5101

KTH Royal Institute of Technology. (2025). *Proactive and Data-Driven Property Management: Bridging the Gap between Property Data and Decision-Making*. Stockholm: School of Architecture and the Built Environment, Department of Real Estate and Construction Management.

Kuppan, K., Acharya, D. B. & Divya, B. (2024). Foundational AI in Insurance and Real Estate: A Survey of Applications, Challenges and Future Directions. *IEEE Access*, 12, 181282–181302. Gefunden unter https://doi.org/10.1109/ACCESS.2024.3509918

LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. Gefunden unter https://doi.org/10.1038/nature14539

Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C. & Hung Byers, A. (2011). *Big data: The next frontier for innovation, competition, and productivity*. Research Report. McKinsey Global Institute. Gefunden unter https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/big-data-the-next-frontier-for-innovation

Mayring, P. (2022). *Qualitative Inhaltsanalyse: Grundlagen und Techniken* (13. Aufl.). Weinheim: Beltz.

McKinsey & Company. (2023). *Generative AI Can Change Real Estate, But the Industry Must Change to Reap the Benefits.* McKinsey Insights. Gefunden unter

https://www.mckinsey.com/industries/real-estate/our-insights/generative-ai-can-change-real-estate-but-the-industry-must-change-to-reap-the-benefits

Monetary Authority of Singapore (MAS). (2024). *Information Paper on GenAI Model Risk and Governance in the Financial Sector*. Singapore: MAS.

Naeem, N., Rana, I. A. & Nasir, A. R. (2023). Digital real estate: a review of the technologies and tools transforming the industry and society. *Smart Construction and Sustainable Cities*, 1(15), 1–21. Gefunden unter https://doi.org/10.1007/s44268-023-00016-0

Pfnür, A. (2011). *Modernes Immobilienmanagement*. Berlin: Springer.

Pfnür, A. & Wagner, B. (2020). Transformation of the real estate and construction industry: empirical findings from Germany. *Journal of Business Economics*, 90(7), 975–1019. Gefunden unter https://doi.org/10.1007/s11573-020-00972-4

Ropeter-Ahlers, S.-E. & Vollrath, J. (2007). Planung von Immobilienportfolios. In K.-W. Schulte & M. Thomas (Hrsg.), *Handbuch Immobilien-Portfoliomanagement* (S. 159–180). Köln: Rudolf Müller.

Russell, S. J. & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4. Aufl.). Hoboken, NJ: Pearson.

Saull, A. & Baum, A. (2020). *Technology and the future of real estate investment management*. Saïd Business School, University of Oxford. Gefunden unter https://www.sbs.ox.ac.uk/sites/default/files/2020-12/Technology%20and%20the%20Future%20of%20Real%20Estate%20Investment%20Management_0.pdf

Saull, A., Baum, A. & Braesemann, F. (2020). Can digital technologies speed up real estate transactions? *Journal of Property Investment & Finance*, 38(4), 349–361. Gefunden unter https://doi.org/10.1108/JPIF-09-2019-0131

Schnell, R., Hill, P. B. & Esser, E. (2018). *Methoden der empirischen Sozialforschung* (11. Aufl.). Berlin: De Gruyter Oldenbourg.

Souza, L. A., Koroleva, O., Worzala, E., Martin, C., Becker, A. & Derrick, N. (2021). The technological impact on real estate investing: robots vs humans: new applications for organisational and portfolio strategies. *Journal of Property Investment &*

Finance, 39(2), 170–177. Gefunden unter https://doi.org/10.1108/JPIF-12-2020-0137

Spence, M. (1973). Job Market Signaling. *The Quarterly Journal of Economics*, 87(3), 355–374. Gefunden unter https://doi.org/10.2307/1882010

Stiglitz, J. E. (2000). The Contributions of the Economics of Information to Twentieth Century Economics. *The Quarterly Journal of Economics*, 115(4), 1441–1478. Gefunden unter https://doi.org/10.1112/0033-5533.00056

Swisscanto. (2026). *Schweizer Pensionskassenstudie 2026: Struktur, Leistung und Reifegrad*. Zürich: Swisscanto Asset Management AG. Gefunden unter https://swisscanto.com/pensionskassenstudie-2026

SwissPropTech. (2025). *SwissPropTech report 2025: Trends und Reifegrad der digitalen Transformation*. SwissPropTech GmbH. Gefunden unter https://swissproptech.ch/study#rec1632157771

Tagliaro, C., Pomè, A. P., Migliore, A. & Danivska, V. (2025). Technology "like a fork": How PropTech shapes real estate innovation. *Journal of European Real Estate Research*, 18(1), 4–26. Gefunden unter https://doi.org/10.1108/JERER-05-2024-0035

Trübestein, M. (2012). Immobilieninvestoren und -anlageprodukte in Deutschland und Österreich. In M. Trübestein (Hrsg.), *Praxishandbuch Immobilieninvestments: Anlagevehikel, Märkte, Strategien in Deutschland und Österreich* (S. 17–44). Gabler Verlag.

UBS. (2024). *UBS Real Estate Focus 2024: Coping with the construction slowdown and the housing shortage in Switzerland*. Zürich: UBS Switzerland AG.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł. & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008. Gefunden unter https://papers.nips.cc/paper/7181-attention-is-all-you-need.pdf

Vigren, O. & Eriksson, K. (2025). A multilayer network model for studying business ecosystems: insights from enterprise architectures in the real estate sector. *Journal of European Real Estate Research*, 18(1), 170–191. Gefunden unter https://doi.org/10.1108/JERER-04-2024-0027

Vigren, O., Kadefors, A. & Eriksson, K. (2022). Digitalization, innovation capabilities and absorptive capacity in the Swedish real estate ecosystem. *Facilities*, 40(15/16), 89–106. Gefunden unter https://doi.org/10.1108/F-07-2020-0083

Viriato, J. C. (2019). AI and machine learning in real estate investment. *The Journal of Portfolio Management*, 45(7), 43–54. Gefunden unter https://doi.org/10.3905/jpm.2019.45.7.043

Wainwright, T. (2023). Rental proptech platforms: changing landlord and tenant power relations in the UK private rental sector? *Environment and Planning A: Economy and Space*, 55(2), 339–358. Gefunden unter https://doi.org/10.1177/0308518X221126522

Węgrzyn, J. (2026). Mining real estate data: A systematic review of text-based approaches. *Real Estate Management and Valuation*, 34(1), 1–15. Gefunden unter https://doi.org/10.2478/remv-2026-0001

Williamson, O. E. (1985). *The Economic Institutions of Capitalism: Firms, Markets, Relational Contracting*. New York: Free Press.

Zhao, Y., Gao, H., Cao, J. & Yang, S. (2026). Utilizing large language models for information extraction from real estate transactions. In *Proceedings of the 2025 4th International Conference on Mathematical Statistics and Economic Analysis (MSEA 2025)* (S. 121–132). Atlantis Press. Gefunden unter https://doi.org/10.2991/978-94-6463-992-6_25

Anhang

Anhang 1: Interviewleitfaden

Der nachstehende Interviewleitfaden wurde für die Erhebung verwendet. Die Reihenfolge der Themenblöcke wurde im Gespräch flexibel gehandhabt, Anschlussfragen wurden ad hoc ergänzt. Für die UK-Interviews wurde dieser Leitfaden auf Englisch übersetzt.

Einleitung in das Forschungsthema (vorab schriftlich übermittelt):

> *Die Studie untersucht das Potenzial Künstlicher Intelligenz – insbesondere Natural Language Processing und Machine Learning – zur Erschliessung unstrukturierter Gebäudedaten für die strategische Steuerung institutioneller Immobilienportfolios. Während strukturierte Daten weitgehend genutzt werden, verbleiben kritische Informationen in Mietverträgen, technischen Berichten und Wartungsprotokollen oft in unstrukturierten Datensilos. Ziel ist es, die Unterscheidung zwischen operativem Asset Management und strategischem Portfolio Management zu schärfen und über einen Marktvergleich mit dem britischen Markt Best Practices zu identifizieren.*

Themenblock A: Strategische Einordnung und Vision

- In welcher Form ist die Analyse unstrukturierter Daten derzeit in Ihrer übergeordneten Portfoliostrategie verankert?
- Wo ziehen Sie die Grenze zwischen operativem Datenmanagement (Asset Management) und der strategischen Nutzung dieser Informationen für die Steuerung des Gesamtportfolios?
- Welche Rolle spielt Künstliche Intelligenz in Ihrer Vision für das Portfolio Management bis zum Jahr 2030?

Themenblock B: KI-Methoden und unstrukturierte Daten

- Bei welchem Prozess verlieren Sie oder Ihr Team aktuell am meisten Zeit durch manuelle Datenerfassung, -suche, -aggregation oder -auswertung (z.B. Due Diligence, CAPEX-Budgetierung)?

- Welche spezifischen KI-Technologien (z.B. Large Language Models für die Vertragsanalyse, Computer Vision für die Zustandsbewertung) halten Sie für den grössten strategischen Hebel?
- Auf welche unstrukturierten Datentypen (z.B. technische Gutachten, komplexe Mietverträge, Wartungsprotokolle) fokussieren Sie sich derzeit primär, um die Informationsqualität auf Portfolioebene zu erhöhen?
- Inwieweit nutzen Sie KI bereits, um aus qualitativen Marktberichten oder News-Feeds Signale für die Risikofrüherkennung im Portfolio zu extrahieren?

Themenblock C: Nutzen und Entscheidungsgüte

- Wie verändert der Einsatz von KI-gestützten Analysen die Qualität Ihrer Investitions- und Desinvestitionsentscheidungen (Exit-Planung)?
- Welchen Mehrwert bietet die automatisierte Extraktion von CAPEX-relevanten Informationen aus technischen Berichten für Ihre langfristige Liquiditäts- und Erneuerungsplanung?
- Wie validieren Sie die Ergebnisse von KI-Modellen, um sicherzustellen, dass strategische Portfolioentscheidungen auf verlässlichen Fakten basieren?

Themenblock D: Implementierung und internationaler Transfer

- Was sind aus Ihrer Sicht die kritischsten organisatorischen Hürden (z.B. Unternehmenskultur, Silo-Denken) bei der Einführung von KI-Systemen?
- Wie beurteilen Sie den Reifegrad des Marktes für spezialisierte PropTech-Lösungen im Bereich Portfolio-Intelligenz im Vergleich UK gegenüber Schweiz?
- Welche Best Practices bei der Standardisierung von Immobiliendaten (z.B. RICS-Standards) sind für eine erfolgreiche KI-Adoption entscheidend?

Anhang 2: Liste der Interviewpartner

Die nachfolgende Tabelle dokumentiert die elf realisierten Interviews. Zur Gewährleistung der Vertraulichkeit wurden personenbezogene Daten bei fehlender Freigabe abstrahiert. Die Tabelle enthält bewusst keine Interview-IDs (I1 bis I12) und folgt einer neutralen Sortierung, um eine Rückverfolgbarkeit einzelner im Text zitierter Aussagen systematisch auszuschliessen.

Name	Unternehmen	Funktion	Datum
Brüllmann, Daniel	UBS AG	Head Real Estate DACH	03.06.2026
Brandt, Julius	DWS Alternatives Global Limited	Chief Digital Investment Officer	21.07.2026
Buck, Jenny	London CIV	CIO	28.07.2026
Mitrovic, Jovica / Laube, Fabian	PSP Swiss Property	Leiter Technology / Leiter Bewirtschaftung & Vermarktung	11.06.2026
Munn, Tim	Swiss Life Asset Managers UK	Co-CEO & CIO	28.07.2026
Pfeiffer, Björn	Swiss Life Asset Managers	Head Real Estate Digital Transformation	22.06.2026
Piffaretti, Renato	Zurich Invest AG	Head Real Estate	10.06.2026
Schärer, Alex	Profond Anlagestiftung	Geschäftsführer	04.06.2026
Wallace, Simon	DWS Alternatives Global Limited	Global Co-Head of Real Estate Research & Head of the UK Real Estate Group	17.07.2026
Wüthrich, Lorenz	Swiss Prime Site Solutions AG	CIO SPA	05.06.2026
(Name und Unternehmen nicht genannt)		Head of Real Estate, Group Asset Management	04.06.2026
(Name und Unternehmen nicht genannt)		Senior Project Manager, Real Assets	03.06.2026

Tabelle: Zusammensetzung des Experten-Samples. Quelle: Eigene Erhebung.

Anhang 3: Codierschema (Endfassung)

Das folgende Codierschema stellt die endgültige Fassung des im Auswertungsprozess verwendeten Analyseinstruments dar. Es verbindet die theoretisch-deduktiv hergeleiteten Hauptkategorien (vgl. Kapitel 3.4, Tabelle 3a) mit den empirisch-induktiv am Material entwickelten Subkategorien (vgl. Kapitel 3.4, Tabelle 3b). Die Strukturierung der Code-Definitionen folgt den wissenschaftlichen Gütestandards qualitativer Methodik.

Kategorie / Code (ID)	Definition (Kurz- & Langform)	Codierregeln (Wann codieren / Wann nicht)	Ankerbeispiel (aus den Interviews I1 bis I12)
K1: Reifegrad „Erprobung“ (SC 1.1)	**Erste informelle Tests und Grundlagenarbeit.** Nutzung generischer KI-Assistenzsysteme auf Einzelebene, ohne dass ein portfolioweit integrierter Anwendungsfall besteht.	**Anzuwenden bei:** Aussagen über informelles Ausprobieren, reine Lizenzvergaben, Fehlen offizieller KI-Strategien im PM. **Nicht anzuwenden bei:** Konkreten Prototypen-Tests mit echtem Datenbezug (dann K2).	„Wir stehen mit KI-Anwendungen im Portfoliomanagement noch ganz am Anfang. Wir haben zwar Lizenzen verteilt, aber es gibt derzeit keine festen operativen Anwendungsfälle im Tagesgeschäft.“ (I4)
K2: Reifegrad „Pilotierung“ (SC 1.2)	**Konkrete, zeitlich begrenzte Erprobung.** Systematische Testphase eines spezifischen, auf unstrukturierte Objektdaten ausgerichteten Anwendungsfalls in einer Laborumgebung.	**Anzuwenden bei:** Beschreibungen von Proof-of-Concepts (PoCs), Hochschulkooperationen oder isolierten Testläufen. **Nicht anzuwenden bei:** Vollständig im Tagesgeschäft verankerten Prozessen (dann K3).	„Wir testen in einer isolierten Laborumgebung ein gemeinsam mit einer Hochschule entwickeltes KI-Modell zur Optimierung unserer Mietzinsstrukturen.“ (I1)
K3: Reifegrad „Punktuelle Integration“ (SC 1.3)	**Produktiver Regelbetrieb eines spezifischen Prozesses.** KI-Ergebnisse fliessen automatisiert in Arbeitsabläufe ein und sind durch Kontrollmechanismen abgesichert.	**Anzuwenden bei:** Beschreibungen stabiler Workflows im Live-System mit definierten Kontrollschwellen. **Nicht anzuwenden bei:** Reinen Machbarkeitsstudien (dann K2).	„Die automatisierte Auslesung und Verarbeitung unserer eingehenden Bauzahlungen läuft produktiv im System und ist durch Plausibilitätsprüfungen abgesichert.“ (I7)
K4: Datenqualität als Restriktion (SC 2.1)	**„Garbage In, Garbage Out“-Problematik.** Die mangelnde Strukturierung, Fehlerhaftigkeit oder ungenügende Konsistenz der operativen Daten verhindert die KI-Nutzung.	**Anzuwenden bei:** Klagen über manuelle Nachbereitungsaufwände, fehlerhafte Stammdaten oder mangelnde Datenpflege. **Nicht anzuwenden bei:** Reinen IT-Schnittstellenproblemen (dann K5).	„Das grösste Hindernis für den KI-Einsatz ist die Qualität der gelieferten Daten. Wenn die operativen Property Manager die Daten nicht sauber pflegen, nützt das beste Modell nichts.“ (I1)
K5: Fragmentierte Systemlandschaft (SC 2.2)	**Existenz technologischer und organisationaler Silos.** Das unverbundene Nebeneinander von ERP-, PM- und Bewertungs-Datenbanken verhindert die Aggregation.	**Anzuwenden bei:** Nennung fehlender Schnittstellen (APIs), Medienbrüchen und unterschiedlichen Datenmodellen bei Drittmanagern. **Nicht anzuwenden bei:** Reiner Datenqualitätskritik (dann K4).	„Unsere Bestandsdaten liegen extrem fragmentiert in den Systemen unterschiedlicher externer Property Manager. Uns fehlt eine einheitliche Plattform für die Aggregation.“ (I8)

K6: Funktionale Trennung PM vs. AM (SC 3.1)	**Diskrepanz der Entscheidungslogiken.** Die unterschiedlichen operativen Anforderungen auf Objektebene stehen der strategischen Portfolio-Perspektive gegenüber.	**Anzuwenden bei:** Aussagen zur Rollentrennung, zu unterschiedlichen Detaillierungsgraden und Kommunikationsbarrieren. **Nicht anzuwenden bei:** Rein technischen Integrationsfragen (dann K7).	„Das Asset Management agiert hochgradig objekt- und mieternah, während wir im Portfolio Management auf aggregierte Szenarien, Allokationen und Risikogrössen angewiesen sind.“ (I3)
K7: KI als Übersetzungsschicht (SC 3.2)	**Erschliessung unstrukturierter Datenpools.** Nutzung von NLP/LLMs zur Überführung heterogener Einzeldokumente in portfoliofähige Kennzahlen.	**Anzuwenden bei:** Plänen oder Beispielen zur automatisierten Auslesung von PDFs (Mietverträge, CAPEX-Berichte) für PM-Systeme. **Nicht anzuwenden bei:** Der reinen Digitalisierung papierhafter Dokumente.	„Die grösste Chance für KI liegt darin, als Brücke zu wirken. Sie muss unstrukturierte PDF-Dokumente wie Mietverträge auslesen und die Daten direkt für Portfolio-Simulationen nutzbar machen.“ (I5)
K8: Letztverantwortung & Kontrolle (SC 4.1)	**„Human-in-the-Loop“-Prinzip.** Organisatorische Pflicht, dass sämtliche KI-generierten Ergebnisse durch qualifizierte Experten manuell plausibilisiert werden.	**Anzuwenden bei:** Nennung von Freigabeprozessen, Stichprobenlogiken, Vier-Augen-Prinzipien und der Haftungsfrage. **Nicht anzuwenden bei:** Der rein technischen Modellvalidierung.	„Wir haben klare Governance-Regeln: Kein KI-Ergebnis wird ungeprüft in unsere Systeme übernommen. Es braucht zwingend die fachliche Plausibilisierung und Freigabe durch einen Menschen.“ (I5)
K4.2: Black-Box-Hürde & XAI (SC 4.2)	**Aufsichtsrechtliche Transparenzanforderungen.** Komplexe, nicht interpretierbare Modellentscheidungen verhindern den Einsatz in regulierten Prozessen.	**Anzuwenden bei:** Erwähnung von Revisionssicherheit, FINMA-Vorgaben, Pflicht zur Nachvollziehbarkeit und erklärbarer KI. **Nicht anzuwenden bei:** Allgemeiner Technologiekritik.	„Als regulierter Schweizer Investor dürfen wir keine Modelle nutzen, deren Entscheidungsfindung eine Black Box bleibt. Jede Anlageentscheidung muss für die Revision lückenlos nachvollziehbar sein.“ (I3)
K10: Absorptive Capacity & Training (SC 5.1)	**Organisatorischer Aufbau von KI-Kompetenz.** Etablierung interner Schulungen, Prompt-Workshops, Zielvereinbarungen oder Kompetenzteams (CoEs).	**Anzuwenden bei:** Nennung konkreter Ausbildungsmassnahmen, unternehmensweiter Trainings oder strategischer Jahresziele. **Nicht anzuwenden bei:** Rein individueller Aneignung von Wissen.	„Wir schulen unsere Mitarbeitenden systematisch in der Prompt-Gestaltung und haben KI-Ziele fest in den jährlichen Leistungsvereinbarungen verankert.“ (I2)
K11: Kulturelle Barrieren & Ängste (SC 5.2)	**Menschliche Widerstände im Veränderungsprozess.** Angst vor Kontrollverlust, Arbeitsplatzabbau oder Entwertung des eigenen Spezialistenwissens.	**Anzuwenden bei:** Erwähnung von Vorbehalten in den Teams, Skepsis gegenüber dem Mehrwert oder mangelnder Nutzerakzeptanz. **Nicht anzuwenden bei:** Sachlichen Budgetrestriktionen.	„Die grösste Hürde ist oft der kulturelle Wandel. Viele Experten fürchten, dass KI ihr mühsam erworbenes Erfahrungswissen entwertet oder sie überflüssig macht.“ (I5)
K12: Transparenz- & Datenkontext (SC	**Marktstrukturelle Unterschiede Schweiz vs. UK.** Der Einfluss der Standardisierung und Datenver-	**Anzuwenden bei:** Direktem Vergleich der Märkte, Erwähnung von MSCI/IPD im UK,	„Im UK haben wir durch die jahrzehntelange MSCI-Standardisierung einen extrem

6.1)	fügbarkeit auf die Geschwindigkeit der AI-Adoption.	REIDA in der Schweiz oder dem Mieterschutz (OR). **Nicht anzuwenden bei:** Rein theoretischen Marktanalysen ohne KI-Bezug.	reifen, validierten Datenpool. In der Schweiz ist das durch lokale Insellösungen deutlich schwieriger.“ (I9)

Ehrenwörtliche Erklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit selbstständig und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt habe. Mir ist bekannt, dass ich die volle Verantwortung für die Wissenschaftlichkeit des vorgelegten Textes selbst übernehme, auch wenn KI-Hilfsmittel eingesetzt und deklariert wurden. Alle Stellen, die wörtlich oder sinngemäss aus veröffentlichten oder nicht veröffentlichten Schriften entnommen wurden, sind als solche kenntlich gemacht. Die Arbeit ist in gleicher oder ähnlicher Form oder auszugsweise im Rahmen einer anderen Prüfung noch nicht vorgelegt worden.

Zürich, den 04.09.2026



_____

Anina Senn