

Ergebnisbericht der Ausschüsse Lebensversicherung und Actuarial Data Science

Einsatz von Whitebox KI in der Bestandsmigration

Köln, 9. Januar 2026

Präambel

Die gemeinsame Arbeitsgruppe Bestandsmigration in der Lebensversicherung der Ausschüsse Lebensversicherung und Actuarial Data Science der Deutschen Aktuarvereinigung e. V. (DAV) hat den vorliegenden Ergebnisbericht erstellt.¹

Anwendungsbereich

Der Ergebnisbericht betrifft Aktuarinnen und Aktuarien² bei der Ausführung aktuarieller Aufgaben im Rahmen der Bestandsmigration in der Lebensversicherung.

Der Ergebnisbericht ist an die Mitglieder und Gremien der DAV zur Information über den Stand der Diskussion und die erzielten Erkenntnisse gerichtet und stellt keine berufsständisch legitimierte Position der DAV dar.³

Inhalt

Eine Bestandsmigration stellt für Lebensversicherer eine komplexe Herausforderung dar, bei der der Einsatz von KI, Machine Learning und Automatisierung große Vorteile bringen kann. Neben den positiven Effekten in der Migration können die gewonnenen Erkenntnisse und die entwickelten Tools und Anwendungen anschließend auch in der laufenden Bestandsverwaltung und bei künftigen Migrationen genutzt werden.

Der Ergebnisbericht behandelt entsprechend diverse Fragestellungen zum Einsatz von generativer KI für aktuarielle Fragestellungen im Rahmen der Bestandsmigration in der Lebensversicherung und betrifft Aktuarien bei der Ausführung aktuarieller Aufgaben im Rahmen der Bestandsmigration. Der Bericht bietet zudem Kriterien zur Bewertung von Tools und Modellen sowie praktische Use Cases, die teilweise auch bereits prototypisch in Tools und Anwendungen umgesetzt wurden.

Schlagworte

Migration, Bestandsmigration, Lebensversicherung, generative KI, Machine Learning, Maschinelle Analyse, Automatisierung, LLM, Referenzrechner, EXCEL-Rechner, Python

Verabschiedung

Dieser Ergebnisbericht ist durch den Ausschuss Lebensversicherung am 9. Januar 2026 verabschiedet worden.

¹ Der Ausschuss dankt der Arbeitsgruppe Bestandsmigration ausdrücklich für die geleistete Arbeit, namentlich Dr. Sven Grönwäller (Leitung), Silke Banzhaf, Dr. Mark-Roman Feodoria, Dmytro Furer, Vjaceslavs Geveilers, Stefan Griep, Thorsten Hanßmann, Axel Helmert, Felix Hübner, Bartłomiej Maciaga, Dr. Helmut Morgenroth, Dr. Christian Nagel, Dirk Nötzel, Mathias Ott, Dr. Arno Rasch (Gast), Nils Rautenberg, Johannes Renfordt, Heike Richter, Claudia Schmidt, Nadja Schnell, Barbara Winter, Dr. Frank Wittemann

² Auch wenn hier und im Folgenden die Aktuarinnen und Aktuarien explizit genannt werden, spricht die DAV alle Geschlechter und Identitäten gleichermaßen an. Dies gilt auch für alle anderen hier genannten Personengruppen.

³ Die sachgemäße Anwendung des Ergebnisberichts erfordert aktuarielle Fachkenntnisse. Dieser Ergebnisbericht stellt deshalb keinen Ersatz für entsprechende professionelle aktuarielle Dienstleistungen dar. Aktuarielle Entscheidungen mit Auswirkungen auf persönliche Vorsorge und Absicherung, Kapitalanlage oder geschäftliche Aktivitäten sollten ausschließlich auf Basis der Beurteilung durch eine(n) qualifizierte(n) Aktuar DAV/Aktuarin DAV getroffen werden.

This abstract summarises the report on findings „Einsatz von Whitebox KI in der Bestandsmigration“ which was approved by the DAV committees Lebensversicherung and Actuarial Data Science on 9 January 2026.

Use of Whitebox AI in Portfolio Migration

A portfolio migration represents a complex challenge for life insurers, where the use of AI, machine learning and automation can provide significant benefits. Beyond the positive effects during the migration itself, the insights which were gained as well as the tools and applications which were developed, can subsequently be applied in the ongoing management of the portfolio and in future migrations.

This report therefore addresses various questions concerning the use of generative AI for actuarial tasks in the context of portfolio migration in life insurance. In addition, the report presents criteria for evaluating tools and models, as well as practical use cases, some of which have already been implemented in prototype tools and applications.

Reports on findings are summaries of the results of work carried out by DAV committees or working groups,

- where their application can be freely decided upon within the framework of the code of conduct,
- that should inform discussion of the current opinion among actuaries or also among the broader public.

As working results of a single committee, they do not, for the time being, represent any recognised position within the DAV and do not comprise any actuarial standards of practice. In this respect they are clearly distinguishable from any standards of practice.

1. Zusammenfassung.....	5
2. Bewertungskriterien für den Einsatz von KI und modernen Methoden in der Bestandsmigration	6
2.1. Daten, Datenschutz und Informationssicherheit	6
2.2. Technik, Infrastruktur, Werkzeuge	6
2.3. Aufwand und Nutzenpotenzial	7
2.4. Modellbezogene Bewertung.....	7
3. Mögliche Anwendungsfälle für den Einsatz von KI	7
3.1. Prozesslandkarte	7
3.2. Use Cases.....	8
3.2.1. Use Case 1: Maschinelle Analyse der Produktunterlagen	8
3.2.2. Use Case 2: Maschinelles Lernen (ML) und RPA in der Bestandsvorbereitung.....	9
3.2.3. Use Case 3: Programmierhilfen für Rechenkernentwicklung.....	9
3.2.4. Use Case 4: Maschinelle Umsetzung der Produktdaten im Zielsystem	10
3.2.5. Use Case 5: Automatisierung der Datentransformation	11
3.2.6. Use Case 6: Maschinelle Generierung der Referenzwerte	11
3.2.7. Use Case 7: KI-Unterstützung beim Test/Verifikation der ETL-Strecke.....	12
3.2.8. Use Case 8: Automatische Generierung von Testbeständen	12
3.2.9. Use Case 9: KI-Modelle im Migrationscontrolling.....	13
4. Ausarbeitung zu den Use Cases 3 und 6: Portierung eines Excel-Tarifrechners in Python mithilfe von Large Language Models.....	14
4.1. Motivation und Rahmenbedingungen des Use Cases.....	14
4.2. Beschreibung der methodischen Herangehensweise	14
4.2.1. Schritt 1: Analyse des Excel-Rechners	15
4.2.2. Schritt 2: Vorbereitung der Datenstruktur	15
4.2.3. Schritt 3: KI-gestützte Portierung mithilfe eines LLM	15
4.2.4. Schritt 4: Validierung und Debugging	15
4.3. Erkenntnisse und Herausforderungen	15
4.4. Bewertung des Einsatzes von LLM bei der Portierung	16
5. Schlusswort und Ausblick mit Danksagung	16

1. Zusammenfassung

Für einen Lebensversicherer gehört eine Bestandsmigration zu den großen Herausforderungen im Geschäftsbetrieb. Insbesondere für die aktuariellen Aspekte einer solchen Migration bietet es sich an, den Einsatz von Künstlicher Intelligenz (KI), Machine Learning (ML) und Automatisierungslösungen zu beleuchten.

Dabei stehen häufig zeitliche und finanzielle Aspekte im Vordergrund: Der Einsatz von KI kann den Zeitaufwand für eine actuarielle Bestandsmigration erheblich reduzieren, indem z.B. große Datenmengen in kurzer Zeit analysiert und geordnet werden können. KI-Algorithmen sind insbesondere hervorragend für die Erkennung von Mustern, Gemeinsamkeiten, Unterschieden und Anomalien in Daten geeignet. Über alle Phasen einer Migration hinweg können so Prozesse, die bei herkömmlicher Bearbeitung Wochen und Monate dauern würden, auf Tage oder sogar Stunden verkürzt werden. Die knappen Ressourcen der Fachexperten und Aktuarien können dann von repetitiven Aufgaben entlastet werden und für komplexere Themenstellungen, auch im Rahmen der Steuerung und Überwachung der KI, eingesetzt werden. Durch die kürzere Timeline und den gezielteren Einsatz der aktuariellen Experten können sich, trotz anfänglicher Investitionen in KI-Technologien und Infrastruktur, sehr positive Effekte auf die Kosten-Nutzen-Bilanz ergeben.

Viele Erkenntnisse aus der Nutzung von KI und ML sowie viele Automatisierungslösungen können in der weiteren Bestandsverwaltung und bei zukünftigen Migrationen erfolgreich genutzt werden.

Für einen umfassenden Blick auf den Einsatz von KI in Bestandmigrationen müssen auch regulatorische Aspekte und weitere Rahmenbedingungen berücksichtigt werden. Diese hängen stark von der individuellen Ausgestaltung des Anwendungsfalls ab, deshalb werden diese Aspekte hier nur am Rande behandelt.

Der Bericht stellt eine Auswahl an Bewertungskriterien für die Beurteilung der Eignung von Tools und Modellen für einen bestimmten Anwendungsfall sowie eine Reihe von Use Cases dar. Diese helfen dabei, erste Schritte für den Einsatz von KI und anderen modernen Methoden in diesem Umfeld zu planen. Die hier vorgestellten Use Cases werden bereits in der Praxis in unterschiedlichen Ausbaustufen angewendet. Für zwei der beschriebenen Use Cases erfolgte durch die Arbeitsgruppe eine prototypische Umsetzung, welche in Kapitel 4 beschrieben ist.

Erklärbarkeit und Whitebox-Verfahren

Im Kontext aktuarieller Anwendungen mit KI rückt zunehmend die **Erklärbarkeit** der Ergebnisse in den Vordergrund. Dabei steht nicht die vollständige Transparenz des zugrunde liegenden Algorithmus im Mittelpunkt, sondern die **Nachvollziehbarkeit der konkreten Resultate** auf Basis fachlicher Kriterien.

Ein Modell gilt als erklärbar, wenn sich seine Ausgaben anhand nachvollziehbarer Strukturen begründen lassen – etwa durch den Bezug zu real existierenden Fachgrundlagen, wie juristische Dokumente (z. B. AVB) oder mathematische Modellierungsregeln der Versicherungstechnik.

Erklärbarkeit bedeutet dabei insbesondere:

- **Übereinstimmung mit bekannten und überprüfbaren Grundlagen:** Die Ausgaben eines Modells lassen sich fachlich schlüssig mit bestehenden Informationen verknüpfen – z. B. durch Bezug zu Paragraphen, Formeln oder vertraglichen Parametern.
- **Einbettung in anerkannte actuarielle Standards:** Die Ergebnisse sind nicht nur formal korrekt, sondern stehen im Einklang mit anerkannten Prinzipien der Versicherungsmathematik und regulatorischen Anforderungen.
- **Prüfbarkeit und Kommunikation:** Die abgeleiteten Ergebnisse sind für Fachanwender plausibel erklärbar und lassen sich gegenüber Dritten – z. B. Revisionsstellen oder Aufsichtsbehörden – konsistent darstellen.

Ein hoher Grad an Erklärbarkeit schafft Vertrauen in KI-gestützte Verfahren – insbesondere in sensiblen Anwendungsfeldern wie der Produktmodellierung, Migration oder automatisierten Vertragsauswertung.

In diesem Bericht bezeichnen wir KI-gestützte Verfahren als **Whitebox-Verfahren**, wenn konkrete Ergebnisse fachlich nachvollziehbar und transparent hergeleitet sowie auf anerkannte Quellen (z. B. AVB, Geschäftspläne, Parameterlisten) zurückgeführt werden können.

2. Bewertungskriterien für den Einsatz von KI und modernen Methoden in der Bestandsmigration

Die Entscheidung, ob ein bestimmtes Modell oder Tool für eine konkrete Aufgabe im Rahmen eines Migrationsprojekts geeignet ist, lässt sich nicht pauschal treffen. Sie hängt stets vom spezifischen Kontext ab – etwa von der Struktur und den Anforderungen des jeweiligen Versicherungsunternehmens, der technischen Infrastruktur, der regulatorischen Umgebung sowie den vorhandenen personellen Ressourcen. Ein Tool kann in einem Unternehmen äußerst sinnvoll und produktiv einsetzbar sein, während es in einem anderen, aufgrund anderer Rahmenbedingungen, ungeeignet erscheint. Die nachfolgenden Themenbereiche umfassen zentrale Kriterien, die bei der fachlich fundierten Bewertung eines Modell- oder Tooleinsatzes berücksichtigt werden müssen.

2.1. Daten, Datenschutz und Informationssicherheit

Zunächst ist der Schutzbedarf der eingesetzten Daten und der daraus resultierenden Ergebnisse zu analysieren. Dabei sind Fragen nach der Herkunft der Daten (öffentlich verfügbar oder unternehmensintern) sowie nach deren Sensibilität zu klären – insbesondere, ob personenbezogene oder sogar besonders schützenswerte Daten verwendet werden. Je nach Schutzbedarf ist beispielsweise die Verwendung der Daten in öffentlich zugänglichen KI-Systemen oder eine Cloud-Speicherung in einem Drittland ggfs. nicht zulässig. In den meisten Fällen müssen firmeninterne KI-Lösungen und geschützte Cloud-Umgebungen genutzt werden. Ebenso wichtig ist die Festlegung, wer Zugriff auf die Daten und Ergebnisse erhält, ob dieser Zugriff personalisiert oder über allgemeine Benutzerkonten erfolgt, und ob eine firmenweite oder streng gruppenbezogene Zugriffsregelung erforderlich ist.

Ein weiterer Aspekt betrifft die Datenqualität: Welche Mindestanforderungen müssen erfüllt sein, damit das Modell oder Tool verlässliche Ergebnisse liefert? Wie robust ist der Einsatz gegenüber lückenhaften oder fehlerhaften Daten? Darüber hinaus ist zu prüfen, ob die zur Verfügung stehenden Datenmengen – für Training, Validierung und produktiven Einsatz – ausreichen, und welcher Aufwand für ihre Aufbereitung, Validierung und Integration zu erwarten ist.

Auch Verantwortlichkeit und Fairness spielen eine Rolle: Liefert das Tool lediglich Vorschläge oder trifft es Entscheidungen? Ist sichergestellt, dass ein „Human-in-the-Loop“-Ansatz implementiert ist? Und wie wird sichergestellt, dass ein potenzieller Datenbias erkannt und angemessen behandelt wird, sodass keine Benachteiligung einzelner Personengruppen entsteht?

2.2. Technik, Infrastruktur, Werkzeuge

Ein zentrales Kriterium ist die technische Kompatibilität mit der vorhandenen IT-Infrastruktur. Erfordert das Tool spezielle Hardware oder ist es auch auf Standardarbeitsplätzen einsetzbar? Welche dauerhafte Infrastruktur wird benötigt, und sind Wartung, Betrieb und Lizenzkosten langfristig planbar?

Zudem ist zu klären, ob das Tool On-Premise oder in der Cloud betrieben werden soll – und wenn in der Cloud, in welcher Ausprägung (Infrastructure as a Service - IaaS, Product as a Service - PaaS, Software as a Service - SaaS). In der Praxis werden oft hybride Lösungen eingesetzt. Auch Skalierbarkeit und Anpassungsfähigkeit müssen berücksichtigt werden: Lässt sich das Tool für größere Datenmengen oder veränderte Anforderungen effizient weiterentwickeln?

Im Hinblick auf eingesetzte Methoden und Komponenten stellt sich die Frage, ob proprietäre oder Open-Source-Werkzeuge integriert sind, welche Lizenzbedingungen gelten, wie Updates gehandhabt werden und wer für die Wartung der gesamten Tool- und Modelllandschaft verantwortlich ist. Zudem ist zu prüfen, welche Qualifikationen die Nutzer benötigen: Können berechnete Mitarbeiter das Tool nach entsprechender Einarbeitung nutzen oder sind spezielle Kenntnisse erforderlich? Gegebenenfalls müssen auch Rollenmodelle, Aufgabenverteilungen und Arbeitsabläufe angepasst werden.

2.3. Aufwand und Nutzenpotenzial

Die Einführung eines Tools ist stets mit initialem Aufwand verbunden. Insbesondere die Datenaufbereitung für Training, Validierung, Test und produktive Nutzung kann umfangreich sein – je nachdem, ob die benötigten Daten bereits in geeigneter Form vorliegen (etwa im Data Warehouse) oder zunächst erhoben und transformiert werden müssen.

Gegenüberzustellen ist der potenzielle Nutzen: Welche Effizienzgewinne werden im Vergleich zu bisherigen Verfahren erreicht – etwa in Form von Zeitersparnis oder Kostenreduktion? Wie oft wird das Tool voraussichtlich eingesetzt, und rechnet sich der Aufwand über die geplante Nutzungsdauer?

Neben der Effizienz ist zu bewerten, ob qualitative Verbesserungen erreicht werden – etwa durch erhöhte Ergebnisgüte, beschleunigte Durchlaufzeiten oder die Entlastung knapper personeller Ressourcen. Ebenso relevant ist die Frage nach der Mehrfachverwendung: Kann das Tool für unterschiedliche Anwendungsfälle innerhalb des Migrationsprojekts oder auch darüber hinaus eingesetzt werden?

2.4. Modellbezogene Bewertung

Die Eignung eines Modells hängt maßgeblich von den zugrunde liegenden Annahmen ab. Je mehr Annahmen ein Modell enthält, desto wichtiger ist deren Transparenz und Plausibilisierbarkeit. Auch die Sensitivität gegenüber Änderungen in den Eingabedaten oder in den getroffenen Annahmen ist zu betrachten: Reagiert das Modell stabil oder stark schwankend?

Die Qualität der Modellprognosen bzw. -ergebnisse ist anhand definierter Kennzahlen zu bewerten – etwa Genauigkeit, Fehlerquote oder Abdeckungsgrad. Für jede gewählte Metrik muss festgelegt werden, welcher Wert angestrebt wird und was in der Praxis als akzeptabel gilt.

Ein weiterer zentraler Aspekt ist die Generalisierungsfähigkeit: Kann das Modell auch auf bisher unbekannte, aber strukturähnliche Daten angewendet werden? Darüber hinaus sind Interpretierbarkeit und Reproduzierbarkeit kritisch: Lassen sich die Ergebnisse fachlich erklären und belegen? Können die Resultate nachvollzogen und unter vergleichbaren Bedingungen wiederholt erzielt werden – und wie wichtig ist dies im konkreten Anwendungsfall?

3. Mögliche Anwendungsfälle für den Einsatz von KI

3.1. Prozesslandkarte

Dargestellt wird das Schema eines Migrationsablaufs mit Fokus auf den aktuariellen und technischen Tätigkeiten.

Die in der Prozesslandkarte auf der folgenden Seite aufgeführten Aufgaben beziehen sich unter anderem auf den ersten Ergebnisbericht der Arbeitsgruppe, der am 20.09.2024 unter dem Titel „Bestandsmigration in der Lebensversicherung“ veröffentlicht wurde.

Neben einigen dieser Aufgaben sind die Nummern der Use-Cases verzeichnet, welche bei der jeweiligen Aufgabe unterstützen können.

Zeitablauf einer Bestandsmigration




Abbildung 1: Aufgaben einer Bestandsmigration und die Zuordnung von KI-Anwendungen

3.2. Use Cases

3.2.1. Use Case 1: Maschinelle Analyse der Produktunterlagen

In Migrationsprojekten sind Informationen zu den zu migrierenden Tarifen für verschiedene Teilprojekte und Fachbereiche essenziell – insbesondere für Produktmathematik, Test, Prozesse oder Rechenkernentwicklung. Die relevanten Inhalte befinden sich jedoch in einer Vielzahl unterschiedlicher Dokumente, die in diversen Formaten (Word, LaTeX, PDF, Scans) vorliegen. Dazu zählen juristische Dokumente wie Allgemeine Versicherungsbedingungen (AVB) oder allgemeine Verbraucherinformationen ebenso wie mathematisch-technische Unterlagen, etwa Geschäftspläne, §143-Meldungen oder interne Kalkulationsbeschreibungen.

Ziel ist es, den beteiligten Nutzergruppen die wesentlichen Merkmale der Produkte schnell, verständlich und vollständig zur Verfügung zu stellen. Aufgrund der in der Regel standardisierten Struktur dieser Dokumente ist der Einsatz moderner KI-Methoden zur Analyse besonders geeignet.

Neben der klassischen Textanalyse – etwa zur strukturierten Extraktion von Informationen aus juristischen Texten – sind heutige KI-Systeme auch in der Lage, fachlich hochkomplexe Inhalte wie Rechenvorschriften, Bedingungsketten oder Formelwerke korrekt zu interpretieren. Besonders leistungsfähig sind hierbei sogenannte Retrieval-Augmented Generation (RAG)-Systeme. Diese kombinieren eine semantische Dokumentensuche mit generativen Sprachmodellen: Zunächst wird

auf Basis vektorisierter Dokumenteninhalte eine kontextbezogene Suche durchgeführt. Anschließend erzeugt ein KI-Modell auf Grundlage der gefundenen Passagen strukturierte, verständliche Antworten – etwa auf Fragen wie: „Welche Rechnungsgrundlagen gelten für Tarif XY?“ oder „Wie ist die Dynamik in diesem Produkt geregelt?“.

Das System erkennt dabei nicht nur identische Begriffe, sondern auch fachlich verwandte Formulierungen und kann relevante Textstellen auch in umfangreichen, unstrukturierten Dokumenten zuverlässig identifizieren. Damit lassen sich wesentliche Inhalte zielgerichtet aufbereiten und strukturiert zur Verfügung stellen.

Ein weiterer bedeutender Anwendungsfall liegt in der vergleichenden Analyse ähnlicher Tarife. Auf Basis semantisch analysierter Dokumentstrukturen kann automatisiert ermittelt werden, wie sich zwei oder mehrere Tarife hinsichtlich zentraler Merkmale – wie z. B. Leistungsumfang, Rechnungsgrundlagen oder Stornoregeln – voneinander unterscheiden oder ähneln. Dies ist insbesondere hilfreich, wenn Varianten eines Produkts in mehreren Generationen migriert werden oder im Zielsystem Redundanzen vermieden werden sollen.

Die so gewonnenen Informationen sind nicht nur im Kontext der initialen Tarifanalyse wertvoll, sondern lassen sich auch in weiteren Bereichen eines Migrationsprojekts nutzen – beispielsweise für die Prozessautomatisierung, die Entwicklung von Testfällen oder die Erstellung von Schnellübersichten für den Kundenservice. Auch für die maschinelle Generierung von Referenzwerten (vgl. Use Case 6) bilden sie eine zentrale Grundlage.

In der Praxis zeigt sich: Der Einsatz von KI-gestützten Auswertungsverfahren für Produktunterlagen erhöht nicht nur die Effizienz in der Informationsbereitstellung, sondern verbessert auch die Nachvollziehbarkeit und Qualität in der Umsetzung komplexer Tarife im Zielsystem – sowohl für die Einzeltarifanalyse als auch im Rahmen tarifübergreifender Vergleiche.

3.2.2. Use Case 2: Maschinelles Lernen (ML) und RPA in der Bestandsvorbereitung

Eine zentrale Voraussetzung für eine erfolgreiche Bestandsmigration ist die hohe Qualität des zu migrierenden Vertragsbestandes – insbesondere im Hinblick auf dessen innere Konsistenz. Damit sind fachlich korrekte und technisch konsistente Vertragsdaten gemeint, die keine Widersprüche enthalten und sich systemseitig verarbeiten lassen.

Zur Identifikation von Auffälligkeiten im Bestand können statistische Verfahren und Methoden des Maschinellen Lernens (ML) eingesetzt werden. Diese ermöglichen die Bildung von sogenannten Abweichungs-Clustern, also Gruppen von Verträgen mit ähnlichen Datenunplausibilitäten. Die erkannten Auffälligkeiten lassen sich anschließend klassifizieren – etwa als historisch bedingte Abweichungen oder als Inkonsistenzen im Verhältnis zu den gültigen Tarifregeln zum Migrationszeitpunkt.

Nach der Erkennung solcher Unstimmigkeiten besteht die Möglichkeit, diese automatisiert zu korrigieren. Hierfür eignen sich toolgestützte Verfahren wie Robotic Process Automation (RPA), mit deren Hilfe beispielsweise rückwirkende Korrekturen an Vertragsdaten durchgeführt und anschließend automatisch fortgeschrieben werden können. Auf diese Weise lässt sich die Bestandsqualität großflächig verbessern – bei gleichzeitiger Reduktion des manuellen Aufwands.

In der Praxis zeigt sich, dass durch den kombinierten Einsatz von ML zur Identifikation und RPA zur anschließenden Bearbeitung ein erheblicher Effizienzgewinn erzielt werden kann. Die Verfahren lassen sich skalierbar einsetzen und unterstützen dabei, auch bei großen Beständen eine konsistente Datenbasis für die Migration zu schaffen.

3.2.3. Use Case 3: Programmierhilfen für Rechenkernentwicklung

Die Entwicklung und Anpassung von Rechenkernen gehört in Migrationsprojekten zu den aufwändigsten Aufgaben. Zahlreiche Tarife müssen im Zielsystem neu angelegt oder angepasst werden – inklusive der jeweiligen Berechnungs- und Verwaltungslogiken. Um den damit verbundenen Aufwand zu reduzieren, bieten moderne KI-gestützte Tools eine wertvolle Unterstützung.

Diese Tools, häufig basierend auf großen Sprachmodellen, assistieren bei der Programmierung, ohne sie vollständig zu automatisieren. Sie liefern Vorschläge, die vom Entwickler validiert und angepasst werden. Typische Einsatzfelder sind:

- Unterstützung bei wiederkehrenden Codemustern, etwa für Schleifen oder Bedingungsstrukturen,
- automatisierte Generierung von Kommentaren und Dokumentation, basierend auf dem vorhandenen Quellcode,
- Vorschläge für Modellierungserweiterungen, unter Rückgriff auf projektbezogene oder domänenspezifische Kontexte.

Ein zusätzlicher Nutzen ergibt sich in der Aufbereitung komplexer Codebasen für weniger erfahrene Anwender. Versicherungstechnische Rechenkerne sind oft über viele Jahre gewachsen, stark modularisiert und fachlich anspruchsvoll. Für neue Mitarbeitende oder Nutzende mit wenig technischem Spezialwissen ist der Einstieg entsprechend herausfordernd. GenAI-gestützte Assistenzsysteme können dabei helfen, Funktionen und Zusammenhänge verständlich darzustellen – etwa durch kontextbezogene Erklärungen, grafische Übersichten oder interaktive Fragestellungen zur Funktionsweise einzelner Komponenten. So wird der Zugang erleichtert und das Onboarding technischer sowie fachlicher Nutzer beschleunigt.

Entscheidend ist: Die Kontrolle bleibt beim Entwicklungsteam. Die KI schlägt vor – die Entscheidung trifft der Mensch. In dieser kooperativen Arbeitsweise liegt der Nutzen: Effizienzgewinne bei Routineaufgaben und komplexem Wissenstransfer, ohne Verzicht auf fachliche Kontrolle.

Insbesondere bei Migrationsprojekten mit vielen parallelen Tarifimplementierungen kann der gezielte Einsatz solcher Werkzeuge die Entwicklungszeiten verkürzen, die Dokumentation verbessern und die Wartbarkeit langfristig erhöhen.

3.2.4. Use Case 4: Maschinelle Umsetzung der Produktdaten im Zielsystem

Die traditionelle Umsetzung eines neuen Tarifs im Zielsystem erfolgt meist auf Grundlage des Geschäftsplans und weiterer fachlicher Dokumente. Dabei wird häufig ein vorhandener Tarif als Kopiervorlage genutzt. Die im Bestand enthaltenen Vertragsdaten werden typischerweise erst zu einem späteren Zeitpunkt im Rahmen der Implementierungstests herangezogen.

Ein alternativer Ansatz bietet sich in Zielsystemen an, die bereits über ein umfangreiches, modulares Tarif- und Formelwerk verfügen. Hier kann die maschinelle Umsetzung neuer Produkte durch die intelligente Kombination vorhandener Berechnungslogiken erfolgen. Grundlage bilden dabei Testrechnungen mit realen Bestandsdaten, aus denen – durch Vergleich der Eingabe- und Ausgabe – die zugrunde liegenden Rechenformeln abgeleitet werden. Diese werden anschließend mithilfe bestehender Systemfunktionen zu einem funktionsfähigen Zieltarif zusammengesetzt.

Die erforderlichen Informationen zu den Berechnungsregeln des Ausgangstarifs können dabei minimal gehalten werden. Dadurch wird die Komplexität der Implementierung deutlich reduziert – insbesondere bei Produkten mit unvollständiger Dokumentation.

Analog zur klassischen Vorgehensweise werden Prüfwerte zur Validierung der gefundenen Formeln herangezogen. Sie dienen dazu, die Übereinstimmung zwischen Quell- und Zielsystem zu überprüfen und Fehler in der maschinellen Herleitung zu identifizieren.

Ein bewusst in Kauf genommener methodischer Unterschied zum traditionellen Ansatz besteht darin, dass nicht immer die originale Abbildung laut Geschäftsplan oder §143-Meldung rekonstruiert wird, sondern eine funktionsfähige Annäherung auf Basis der beobachteten Berechnungen entsteht. Die maschinell erstellte Abbildung ist somit nicht notwendigerweise identisch mit der in der Quelle dokumentierten oder implementierten Logik. Daher eignet sich der Ansatz primär zur Identifikation bereits im System vorhandener Formeln – beispielsweise zur Vermeidung doppelter Implementierungen oder als Ausgangspunkt für weitere fachliche Validierungen. Insbesondere bei genehmigten und angezeigten Produkten muss die maschinell gefundene Lösung mit den genehmigten bzw. eingereichten Produktunterlagen abgeglichen werden und zu diesen mathematisch äquivalent sein.

Aktuelle Entwicklungen ermöglichen zudem die Unterstützung dieser Methode durch KI-basierte Analysetools, die Unterschiede zwischen verschiedenen Berechnungswegen automatisiert erken-

nen und strukturierte Vorschläge zur Rekonstruktion des Zieltarifs liefern. Auch hier liegt die Verantwortung für die Freigabe stets beim Fachteam – die Systeme fungieren als Assistenz, nicht als Ersatz für aktuarielle Prüfung.

Insgesamt bietet der Ansatz der maschinellen Produktumsetzung eine wertvolle Option für Zielsysteme mit stark parametrisierten Tarifwerken – insbesondere zur Beschleunigung und Standardisierung der Produktabbildung bei Migrationen.

3.2.5. Use Case 5: Automatisierung der Datentransformation

Im Rahmen von Migrationen von Lebensversicherungsbeständen unterscheiden sich die Datenmodelle der Quell- und Zielsysteme in der Regel strukturell und inhaltlich. Für eine korrekte und fachlich konsistente Datenübertragung ist es daher erforderlich, eindeutige Regeln zu definieren, wie die Attribute des Zielsystems mit den entsprechenden Informationen aus dem Quellsystem befüllt werden sollen. Diese sogenannten Transformationsregeln sind dabei häufig differenziert nach Produktarten oder spezifischen Vertragsmerkmalen und können in ihrer Gesamtheit sehr komplex werden.

Der bisher übliche Ansatz besteht in einem manuellen Mapping-Prozess: Dabei werden die Beschreibungen der Datenmodelle beider Systeme manuell analysiert und aufeinander abgestimmt, um daraus die notwendigen Transformationsregeln abzuleiten. Anschließend werden diese Regeln in Testläufen auf (Teil-)Bestände angewendet, um zu prüfen, ob die definierten Transformationen korrekt umgesetzt wurden oder ob Anpassungen erforderlich sind.

Ein alternativer, modernerer Ansatz ist die automatisierte Unterstützung der Datentransformation. Hierbei können mithilfe vorhandener Datenmodellbeschreibungen, ergänzender Dokumentationen und durch die Analyse der Bestandsdaten Vorschläge für Transformationsregeln generiert werden. Zwei methodische Ansätze stehen dabei exemplarisch zur Verfügung:

- **Semantische Analyse:**
Durch semantische Analyse der zur Verfügung stehenden Beschreibungen kann ein Abgleich zwischen den Attributen des Quell- und des Zielmodells erfolgen. Auf diese Weise lassen sich potenzielle Zuordnungen der Felder automatisiert identifizieren.
Die semantische Analyse nutzt dabei insbesondere die in Bezeichnern, Beschreibungen und Attributnamen enthaltenen Bedeutungen und Zusammenhänge, um automatisiert fachliche Ähnlichkeiten und Unterschiede zwischen Quell- und Zielstruktur zu erkennen.
- **Maschinelle Auswertung der Bestandsdaten:**
Die maschinelle Auswertung der Bestandsdaten umfasst die Anwendung von Algorithmen zur Erkennung von Mustern, Verteilungen und Abhängigkeiten in den vorhandenen Datenbeständen, um automatisiert auf mögliche Zuordnungen oder notwendige Transformationen zu schließen.

Eine Kombination beider Verfahren – semantische Analyse und datengetriebene Klassifikation – kann dabei helfen, die Qualität der abgeleiteten Transformationsregeln zu erhöhen und den Aufwand für die manuelle Regeldefinition deutlich zu reduzieren.

3.2.6. Use Case 6: Maschinelle Generierung der Referenzwerte

Eine zentrale Aufgabe in Migrationsprojekten ist die Bereitstellung von Referenzwerten. Sie dienen

- dem Abgleich mit Echtdaten aus dem Quellsystem zur Erkennung und Bereinigung von Bestandsfehlern,
- als Prüfwerte zur Validierung der Implementierung im Zielsystem und des Migrationsprozesses,
- sowie als Vergleichswerte für synthetische Bestände, etwa beim Training algorithmischer Verfahren zur Produktabbildung.

In der Praxis bestehen dabei erhebliche Herausforderungen: Ältere Quellsysteme sind oft nicht in der Lage, eine vollständige, nachvollziehbare und detailreiche Berechnung der Referenzwerte bereitzustellen. Meist können nur einzelne Datenpunkte manuell oder über veraltete Schnittstellen extrahiert werden. Zudem ist die Validität der Ergebnisse durch potenzielle Altsystemfehler oder unklare Programmhistorien eingeschränkt.

Aus diesem Grund wird häufig auf separate Kalkulationstools zurückgegriffen – etwa aus der Produktentwicklung oder dem Bestandsmanagement. Diese basieren auf dokumentierten Tarifinformationen und erfüllen regulatorische Anforderungen, erfordern jedoch hohen manuellen Aufwand und binden aktuarielle Kapazitäten.

Zur Effizienzsteigerung können folgende Ansätze genutzt werden:

- **Integration vorhandener Datenquellen:** Eine strukturierte Produktdatenbank mit hinterlegten Parametern und Formelverweisen bildet die Grundlage. Fehlen solche Daten, können sie mittels semantischer Analyse aus Dokumenten extrahiert und systematisch abgelegt werden. Ergänzend wird eine Anbindung an Vertragsdatenbanken und ggf. Dokumentenarchiv (z. B. mit technischen Änderungen) hergestellt.
- **Automatische Code-Generierung:** Liegen Daten und Formeln in geeigneter Struktur vor, können automatisierte Übersetzungen in Rechenlogik erfolgen – z. B. durch Umwandlung aus LaTeX in C++ oder Python, unterstützt durch moderne Entwicklungstools.
- **Nutzung von Bestandteilen des Altsystems:** Wo möglich, kann die Auslagerung von funktionalen Komponenten aus dem Quellsystem – etwa zur Berechnung von Rückkaufswerten oder Deckungskapital – in Container-Anwendungen erfolgen. Dies reduziert die Notwendigkeit vollständiger Nachbauten.

Diese Methoden bieten einen pragmatischen Mittelweg zwischen vollständiger Eigenentwicklung und Rückgriff auf schwer zugängliche Altsysteme. Damit wird eine konsistente, reproduzierbare und fachlich belastbare Referenzwertbildung auch in komplexen Migrationsprojekten ermöglicht.

3.2.7. Use Case 7: KI-Unterstützung beim Test/Verifikation der ETL-Strecke

Ein funktionierender ETL-Prozess (Extract–Transform–Load) ist eine zentrale Voraussetzung für eine erfolgreiche Bestandsmigration. Idealerweise wird die gesamte ETL-Strecke anhand möglichst vieler Verträge überprüft – dieser Aufwand ist jedoch bei manueller Durchführung kaum realistisch zu leisten.

Ein alternativer Ansatz ist der Einsatz einer selbstlernenden KI als automatisierte Qualitätskontrolle. Die KI wird mit Verträgen trainiert, deren Verarbeitung durch manuelle Prüfung als korrekt bewertet wurde. Daraus lernt das Modell, wie ein Vertrag aus dem Quellsystem korrekt im Zielsystem abgebildet sein sollte.

Nach der Trainingsphase kann die KI die Transformation weiterer Verträge eigenständig prüfen. Bei Auffälligkeiten entscheidet der manuelle Prüfer, ob ein Fehler vorliegt. Wird die Transformation als korrekt bestätigt, lernt die KI auch diese Variante als gültig – und wird sie künftig nicht mehr als Abweichung markieren.

Die KI übernimmt somit keine abschließende Bewertung, sondern unterstützt die Prüfung, indem sie sich wiederholende korrekte Muster erkennt und entlastend nur potenzielle Abweichungen meldet. Dadurch wird die Prüftiefe erhöht und gleichzeitig der manuelle Aufwand reduziert – besonders bei großen Beständen mit hoher Wiederholungsrate.

3.2.8. Use Case 8: Automatische Generierung von Testbeständen

Zur Sicherstellung der fachlichen Korrektheit, technischen Stabilität und regulatorischen Konformität einer Bestandsmigration ist eine umfassende Testabdeckung unabdingbar. Die dabei eingesetzten Testfälle müssen ein breites Spektrum an Merkmalen abbilden – von Produktvielfalt über vertragliche Ausprägungen bis hin zu den im Bestand dokumentierten Geschäftsvorfällen.

Moderne Methoden ermöglichen eine automatisierte Unterstützung bei der Erstellung und Strukturierung solcher Testbestände. Insbesondere semantische Analysen von Produktunterlagen (siehe Use Case 1) können dazu genutzt werden, die zentralen Testkriterien systematisch zu erfassen. Auf dieser Basis lassen sich gezielt Testfälle generieren, die typische Konstellationen und Besonderheiten einzelner Produkte abdecken.

Darüber hinaus können die Testbestände entlang relevanter Merkmalsdimensionen in Cluster unterteilt werden. Dies erleichtert sowohl die Abdeckung seltener Konstellationen als auch die gezielte Reaktion auf migrationsrelevante Spezialfälle. Ergänzend hierzu lassen sich Zufallstestfälle automatisiert erzeugen, um unvorhergesehene Implementierungsfehler frühzeitig zu identifizieren. Auch kontrafaktische Testfälle – also bewusst unzulässige oder widersprüchliche Konstellationen – können definiert werden, um die Fehlertoleranz und Robustheit der Systemumsetzung zu überprüfen.

Ein weiteres Anwendungsfeld liegt in der automatisierten Erzeugung von Regressionstestbeständen, die im Zeitverlauf konsistent bleiben und zur Überprüfung von Release-Stabilität dienen. Der Einsatz solcher Bestände erhöht die Nachvollziehbarkeit bei wiederholten Testzyklen und beschleunigt Freigabeprozesse.

Neben der Generierung spielt auch die Qualitätssicherung der Testfälle eine zentrale Rolle. Moderne Testing-Tools mit integrierter Abdeckungsanalyse – etwa durch Kontrollfluss- oder Entscheidungspfadanalysen – können unterstützen, bestehende Lücken in der Testlandschaft systematisch zu identifizieren und gezielt zu schließen.

In Summe bietet die automatische Testgenerierung in Verbindung mit strukturierten Analyse- und Prüfverfahren einen signifikanten Effizienzgewinn. Gleichzeitig steigt die Qualität der Migration, da eine höhere Testabdeckung bei geringerer manueller Belastung erreicht wird.

3.2.9. Use Case 9: KI-Modelle im Migrationscontrolling

Das klassische Migrationscontrolling konzentriert sich primär auf die Überprüfung definierter Prüfwerte in vordefinierten Teilbeständen. Diese regelbasierten Verfahren liefern wichtige Aussagen zur Korrektheit einzelner Transformationen oder Berechnungen. Allerdings stoßen sie in der Praxis auch an Grenzen:

- Die Auswertungen beschränken sich auf im Vorfeld festgelegte Prüfverfahren und Schwellenwerte.
- Eine Ursachenanalyse bei Toleranzverletzungen ist meist manuell und zeitaufwendig.
- Ein Gesamtbild über die fachliche Qualität der Abbildung im Bestand oder deren Entwicklung über die Zeit ist nur mit erheblichem Ressourceneinsatz zu erzeugen.

Durch den ergänzenden Einsatz von Verfahren der Künstlichen Intelligenz – insbesondere aus dem Bereich des Maschinellen Lernens – kann das Migrationscontrolling gezielt erweitert und in zentralen Aspekten entlastet werden. Statt ausschließlich auf vorab definierte Prüfregeln zurückzugreifen, ermöglichen es statistische und datengetriebene Verfahren, auch bislang unbeachtete Muster zu erkennen und zu bewerten.

Beispielhafte Einsatzmöglichkeiten sind:

- Plausibilitätsprüfungen auf Basis von Vergleichswerten: Anstelle starrer Grenzwertkontrollen werden erwartete Zielwerte durch Regressionsmodelle oder Vergleich mit Trainingsdaten bestimmt – etwa zur Bewertung von Rückkaufswerten oder Deckungskapitalverläufen.
- Clustering von Toleranzverletzungen: Abweichungen werden nicht einzeln, sondern in Gruppen analysiert. Dies ermöglicht die Identifikation systematischer Ursachen – z. B. bestimmte Produkttypen, Vertragsmerkmale oder Rechenkonstellationen.
- Maschinelle Ursachenanalyse: ML-Modelle können anhand historischer Migrationsdaten trainiert werden, typische Fehlerbilder zu erkennen und automatisiert deren wahrscheinliche

Ursache zu benennen – beispielsweise fehlerhafte Tarifeinstellungen, Datenlücken oder Systeminkompatibilitäten.

- Prognose künftiger Toleranzverletzungen: Auf Basis vorhandener Merkmalsausprägungen können ML-Modelle eine Vorhersage treffen, in welchen Teilbeständen mit erhöhtem Korrektur- oder Prüfaufwand zu rechnen ist – besonders hilfreich bei tranchenbasierten Migrationen oder beim Testen neuer Releases.

Diese Methoden verstehen sich nicht als Ersatz, sondern als Ergänzung zum klassischen Migrationscontrolling. Sie unterstützen dabei, begrenzte Fachressourcen gezielt auf relevante Fälle zu fokussieren, strukturierte Ursachenanalysen durchzuführen und frühzeitig auf unerwartete Entwicklungen reagieren zu können.

Besonders im Rahmen großer Migrationsprojekte – mit umfangreichen Beständen, vielfältigen Produktausprägungen und mehreren Migrationstranchen – kann der Einsatz KI-gestützter Controllingmodelle die Transparenz, Effizienz und Steuerbarkeit der Migration signifikant erhöhen.

4. Ausarbeitung zu den Use Cases 3 und 6: Portierung eines Excel-Tarifrechners in Python mithilfe von Large Language Models

Die Migration von Bestandsführungssystemen und insbesondere ihren tariflichen Berechnungssystemen zählt zu den komplexesten und zeitintensivsten Aufgaben im Bereich der Lebensversicherungsmathematik. Eine wichtige Voraussetzung bei dieser Aufgabe ist der Einsatz von leicht handhabbaren Referenzrechnern, die es ermöglichen, die Implementierung im Zielsystem unabhängig zu überprüfen. Ein typischer Anwendungsfall von KI ist die Überführung bestehender Excel-basierter Tarifrechner in leistungsfähigere, robuste und wartbare Softwarelösungen, beispielsweise in Python. Der hier beschriebene Use Case beschäftigt sich mit der automatisierten Portierung eines Excel-basierten Produktrechners mittels generativer KI, insbesondere unter Einsatz von Large Language Models (LLMs).

4.1. Motivation und Rahmenbedingungen des Use Cases

Excel-basierte Tarifrechner sind in der Lebensversicherungsbranche weit verbreitet. Sie dienen häufig als Grundlage zur Berechnung von Vertragswerten, als Referenzmodell bei Migrationen oder als Hilfsmittel zur Validierung neuer Implementierungen. Solche Excel-Lösungen wachsen oft über Jahre. Sie bieten in vielen Aufgaben eine schnelle, intuitive Nachvollziehbarkeit, stoßen jedoch – insbesondere bei historisch gewachsener VBA-Logik und in integrierten IT-Landschaften – bei Skalierbarkeit, Wartbarkeit und Reproduzierbarkeit an Grenzen.

Die Überführung in eine moderne Programmiersprache wie Python verspricht erhebliche Vorteile: verbesserte Wartbarkeit durch klar strukturierten Code, höhere Transparenz und Prüfbarkeit, Automatisierungsmöglichkeiten sowie eine Integration in bestehende IT-Landschaften. Die Herausforderung besteht jedoch darin, die fachlich komplexen Berechnungslogiken exakt aus Excel zu extrahieren und fehlerfrei in Python abzubilden. Hierbei zeigt sich ein idealer Anwendungsfall für generative KI: Die automatisierte Unterstützung dieser Portierung mithilfe von Large Language Models (LLM). Gleichwohl soll eine unreflektierte Parallelprogrammierung (Excel ↔ Python) die Fehler aus den ursprünglichen Landschaften nicht duplizieren. Dem wird durch diverse Qualitätssicherungsverfahren aus dem IT-Umfeld, etwa durch Golden-Master-Vergleiche (Python-Outputs vs. Excel-Referenzen), Unit/Property-Tests für Barwerte/Rundungen, fixierte Versionen und ein Human-in-the-Loop-Freigabeverfahren, entgegengewirkt.

4.2. Beschreibung der methodischen Herangehensweise

Die methodische Vorgehensweise bei diesem Use Case kann unterschiedlich ausgestaltet werden. Eine Möglichkeit besteht darin, das Excel-Format in der Interaktion mit dem LLM direkt anzuwenden, was unter der aktuellen Entwicklung der Technik (Verarbeitung des Excels durch ein

LLM) noch nicht unproblematisch ist. Eine andere Methode besteht darin, das Excel-Format durch ein Text-Format zu ersetzen (hier präsentiert). Das Vorgehen verläuft in wenigen Schritten:

4.2.1. Schritt 1: Analyse des Excel-Rechners

In einer initialen Phase wird der bestehende Excel-Tarifrechner detailliert analysiert. Dabei werden sämtliche relevanten Excel-Formeln, Zellbezüge und insbesondere der enthaltene VBA-Code untersucht, um ihre Rolle in der Datenverarbeitung zu verstehen. Ein tiefes Verständnis der Formel selbst ist dabei nicht notwendig, es handelt sich lediglich um gutes Verständnis der Input-/Output-Logik des Excel-Rechners.

Diese erste Bestandsaufnahme dient als Eingabe für das LLM und umfasst insbesondere:

- Excel-Formeln und -Funktionen sowie Zellreferenzen
- VBA-Module mit Basisfunktionen und komplexeren Berechnungsschritten
- Strukturierte Eingabefelder und Outputs, die reproduziert werden müssen

4.2.2. Schritt 2: Vorbereitung der Datenstruktur

Vor Beginn der eigentlichen Code-Portierung werden Input-Daten einmalig in strukturierte CSV-Dateien exportiert, um eine saubere Datengrundlage für die Python-Implementierung zu gewährleisten. Dies betrifft insbesondere Variablen, Konstanten, Tarifdaten und Parameter aus Excel. Durch automatisierte Python-Skripte werden diese strukturierten Daten eingelesen und stehen so für eine effiziente Portierung zur Verfügung. Dadurch vermeidet man, dass komplette Excel-Dateien, samt ihrer komplexen Strukturen und Schnittstellen, dem Modell zur Verfügung gestellt werden. Stattdessen wird nur die essenzielle Berechnungslogik extrahiert, was einen minimalen Kontext für das LLM sichert.

4.2.3. Schritt 3: KI-gestützte Portierung mithilfe eines LLM

In der eigentlichen Portierungsphase kommt ein LLM zum Einsatz. Anhand der zuvor extrahierten Excel- und VBA-Logik generiert das LLM schrittweise den Python-Code. Dabei werden zunächst Basisfunktionen, insbesondere die Barwerte, aus dem VBA-Code in Python-Funktionen übersetzt. Im Anschluss folgen komplexere Ausgabefunktionen, die im Excel-Arbeitsblatt definiert sind (Berechnungen der Netto- und Bruttobeiträge, Verläufe des Deckungskapitals und der Rückkaufswerte usw.).

Besondere Herausforderung hierbei ist, die Struktur des Excel-Rechners vollständig nachzubilden. Dazu zählt insbesondere die exakte Umsetzung von Zellreferenzen, Formeln und abhängigen Funktionen, inklusive der korrekten Behandlung von Groß- und Kleinschreibung („Axn“ vs. „axn“), die für die meisten Programmiersprachen relevant ist.

4.2.4. Schritt 4: Validierung und Debugging

Da eine vollständige Korrektheit der automatischen Portierung selten im ersten Durchlauf gegeben ist, erfolgt ein systematisches Debugging. Dabei unterstützt das LLM aktiv, indem es Vorschläge zur Fehleranalyse liefert und Anpassungen der Implementierung empfiehlt. Wichtige Debugging-Schritte beinhalten:

- Identifikation und Korrektur fehlerhaft übertragener Formeln und Funktionen
- Validierung der Ergebnisse durch direkten Vergleich der Python-Ausgaben mit dem ursprünglichen Excel-Modell
- Schrittweise Korrektur durch iterative Nutzung des LLM, bis vollständige Übereinstimmung zwischen Excel und Python erreicht ist

4.3. Erkenntnisse und Herausforderungen

Im Laufe des konkreten Projekts zeigte sich, dass insbesondere komplexe Formeln aus Excel gewisse Herausforderungen darstellten. Durch den iterativen Austausch zwischen Experten und dem LLM konnten diese Hürden jedoch effizient überwunden werden. Im Ergebnis entstand eine vollständige Python-Implementierung, die eine exakte Übereinstimmung mit den Excel-Ergebnissen

liefert. Die Portierung erfolgte in einem Bruchteil des sonst komplett manuellen Aufwands, war fehlerfrei und ausführlich und systematisch getestet.

Diese Vorgehensweise beinhaltet jedoch einige Voraussetzungen und Herausforderungen, die berücksichtigt werden müssen:

- **Fachliche und technische Expertise:** Die Generierung von hochwertigem Code durch KI erfordert nach wie vor fundierte fachliche Expertise zur Beurteilung der Ergebnisse. Das LLM liefert zwar Vorschläge und automatisiert Teile des Prozesses, entbindet den Aktuar jedoch nicht von der Verantwortung zur Prüfung.
- **Datenstruktur und Vorbereitung:** Die Qualität der Ergebnisse des LLM hängt wesentlich von der Qualität der Input-Daten und der Klarheit der formulierten Anweisungen ab. Ein initialer, gut strukturierter Export aus Excel ist daher essenziell.
- **Regulatorische Anforderungen:** Die Ergebnisse des generierten Codes müssen transparent und prüfbar sein, um regulatorische Anforderungen zu erfüllen. Das LLM unterstützt diesen Anspruch durch detaillierte Dokumentationen, nachvollziehbare Strukturen und umfassende Kommentierung.

4.4. Bewertung des Einsatzes von LLM bei der Portierung

Die automatisierte Unterstützung bei der Portierung eines Excel-Tarifrechners in Python mittels LLMs weist ein erhebliches Effizienzpotenzial auf. Die manuelle Umsetzung der komplexen Berechnungen aus vorhandenen Excel-Rechnern würde erfahrungsgemäß mehrere Wochen in Anspruch nehmen. Durch den Einsatz von generativer KI kann dieser Zeitraum deutlich verkürzt werden – im besten Fall auf wenige Tage intensiver und fokussierter Arbeit. Das einmal etablierte Vorgehen ist auch wiederholbar und durch Einsatz ähnlicher Tools gut skalierbar.

Zudem erhöht sich durch den Einsatz eines LLM die Transparenz und Prüfbarkeit des entstehenden Python-Codes signifikant. Der Generierungsprozess bietet eine strukturierte reproduzierbare Vorgehensweise, die sich auch auf zukünftige Portierungsprojekte übertragen lässt.

Gleichwohl erfordert der Einsatz dieser Technologie eine sorgfältige und qualitätsbewusste Herangehensweise. Die Qualitätssicherung der generierten Ergebnisse und die verantwortungsvolle Nutzung der KI-Unterstützung bleiben Kernaufgaben der beteiligten Experten. Werden diese Aspekte berücksichtigt, ergibt sich ein großer Nutzen im Kontext von Migrationsprojekten.

Dieser Use Case demonstriert eindrucksvoll, wie moderne KI-gestützte Verfahren dazu beitragen können, eine komplexe, bislang weitgehend manuelle Aufgabe im Rahmen von Bestandsmigrationen zu optimieren und dabei gleichzeitig eine hohe Transparenz und Prüfbarkeit sicherzustellen.

5. Schlusswort und Ausblick mit Danksagung

In diesem Bericht wurden verschiedene Einsatzmöglichkeiten von KI im Kontext von Bestandsmigrationen vorgestellt. Die beschriebenen Use Cases decken nahezu den gesamten Migrationsprozess ab – von der Vorbereitung über Konzeption, Implementierung, Migrationstests und Qualitätssicherung bis hin zur eigentlichen Durchführung. Die Integration von KI bietet das Potential, künftige Bestandsmigrationen deutlich effizienter und ökonomischer zu gestalten.

Angesichts der dynamischen Weiterentwicklung im Bereich der KI ist davon auszugehen, dass künftig weitere spannende Anwendungsfelder entlang des Migrationsprozesses erschlossen werden.

Bereits während des Entstehungszeitraumes dieses Berichtes konnten signifikante Fortschritte hinsichtlich der Leistungsfähigkeit von LLM bei der Portierung des Excel-Tarifrechners beobachtet werden. Dies zeigte sich insbesondere in einer sinkenden Anzahl erforderlicher Teilschritte bei gleichzeitig steigender Ergebnisqualität.

Gegenwärtig bestehende Begrenzungen, etwa hinsichtlich der im Rahmen eines Schritts verarbeitbaren Datenmenge, dürften in zukünftigen Modellen deutlich reduziert werden.

Es lohnt sich daher mit Sicherheit, die Entwicklungen auf dem Gebiet der KI weiterhin aufmerksam zu verfolgen und den praktischen Einsatz zu prüfen.

Die Arbeitsgruppe dankt den Mitgliedern des Ausschusses Lebensversicherung für die wertvollen Hinweise im Abstimmungsprozess.