



Informationsarchitektur im Zeitalter der KI

Was sich bei Anforderungen verändert - und was Projekte jetzt neu brauchen

KI macht Requirements Engineering nicht überflüssig. Sie macht diszipliniertes, iteratives und nachvollziehbares Requirements Engineering wichtiger denn je.

KI-gestützte Systeme verändern die Rolle von Anforderungen. Systemverhalten entsteht nicht mehr nur aus spezifizierter Logik, sondern aus dem Zusammenspiel von fachlichem Ziel, Daten, Modell, Evaluation und laufender Beobachtung in Produktion. Damit wird die Informationsarchitektur eines Projekts zur Voraussetzung für Nachvollziehbarkeit.

Autor: Reiner Schindler

Organisation: MORE® Framework™

Version: V1.0 · Juli 2026

Veröffentlichung: more-framework.org

Kurzfassung: Daten ersetzen keine Anforderungen. Sie werden zu einem Anforderungsartefakt erster Klasse. Entscheidend ist die Verbindung von fachlichen Geschäftsbedarf, Anforderung, Datenquelle, Datenqualität, Modellentscheidung, Test, Abnahme, Monitoring und Produktionsnachweis.

1. Ausgangslage: KI verändert die Anforderungsarbeit

In klassischen Softwareprojekten konnte Requirements Engineering häufig von einer relativ stabilen Annahme ausgehen: Ein fachlicher Bedarf wird beschrieben, daraus entstehen Anforderungen, diese Anforderungen werden umgesetzt, getestet, abgenommen und produktiv gesetzt. Diese Linie war nie trivial, aber sie war grundsätzlich nachvollziehbar. Das erwartete Systemverhalten wurde überwiegend durch spezifizierte Logik bestimmt.

Bei KI-gestützten Systemen verschiebt sich diese Grundlage. Das spätere Systemverhalten entsteht nicht mehr ausschließlich durch Code, Regeln und Konfiguration. Es entsteht auch durch Daten, Trainingsprozesse, Modellarchitekturen, Parameter, Schwellenwerte, Evaluationsverfahren und den konkreten Nutzungskontext. Der Übergang von „coding“ zu „training“ verändert damit auch die Anforderungen an Requirements Engineering [1].

Das Problem ist nicht, dass Anforderungen verschwinden. Das Gegenteil ist der Fall. Anforderungen werden wichtiger, weil sie die fachliche Absicht ausdrücken, gegen die Daten, Modelle und Ergebnisse beurteilt werden müssen. Gleichzeitig reichen klassische Anforderungsartefakte allein nicht mehr aus. Wer nur beschreibt, was ein System leisten soll, aber nicht nachvollziehbar hält, mit welchen Daten, welchen Grenzen und welchen Bewertungen dieses Verhalten entsteht, verliert den fachlichen Zusammenhang.

Die neue Frage lautet nicht: Anforderungen oder Daten?

Die neue Frage lautet: Wie werden fachlicher Bedarf, Datenbasis, Modellverhalten und Produktionsnachweis dauerhaft und nachvollziehbar verbunden?

2. Was sich durch KI konkret verändert

KI verändert Anforderungen nicht an einer einzigen Stelle, sondern entlang der gesamten Nachweiskette. Fünf Veränderungen sind besonders relevant.

1. **Systemverhalten wird probabilistischer.** Viele KI-Systeme liefern keine deterministische Regelantwort, sondern Wahrscheinlichkeiten, Klassifikationen, Empfehlungen oder generierte Inhalte. Akzeptanzkriterien müssen deshalb stärker mit Gütemaßen, Fehlertoleranzen, Einsatzgrenzen und menschlicher Kontrolle arbeiten.
2. **Daten werden Teil der Anforderungslage.** Die Qualität der Lösung hängt wesentlich von Verfügbarkeit, Herkunft, Repräsentativität, Aktualität, Bias-Risiken, Nutzungsrechten und Datenqualität ab. Daten sind damit nicht nur technischer Input, sondern fachlich relevante Projektinformation.
3. **Evaluation ersetzt nicht den Test, erweitert ihn aber.** Ein Testfall prüft nicht mehr nur, ob eine Funktion korrekt umgesetzt wurde. Er muss auch zeigen, wie Modellleistung, Robustheit, Erklärbarkeit, Grenzfälle und unerwünschte Nebenwirkungen bewertet wurden.
4. **Abnahme wird zu einem Zustand.** Bei klassischen Systemen markiert die Abnahme häufig einen Zeitpunkt. Bei KI-gestützten Systemen können Datenbasis, Modellleistung und Nutzungskontext driften. Die fachliche Zusage muss daher auch nach dem Go-live beobachtet und erneut belegt werden.
5. **Traceability reicht bis in die Produktion.** Die Nachweiskette endet nicht beim Release. Sie muss Modellversion, Datenstand, Evaluation, fachliche Entscheidung, Monitoring und produktive Beobachtung verbinden.

Fachlicher Bedarf → Anforderung → Datenquelle → Datenqualität → Modellentscheidung → Akzeptanzkriterium → Test/Evaluation → Abnahme → Release → Monitoring → Produktionsnachweis

3. Daten ersetzen Anforderungen nicht

In datengetriebenen Vorhaben entsteht leicht der Eindruck, die Daten seien der eigentliche Startpunkt. Häufig ist das sogar operativ richtig: Ein Team beginnt mit vorhandenen Daten, prüft Muster, baut Prototypen, testet Modellvarianten und nähert sich der fachlichen Lösung experimentell. Für Requirements Engineering ist daraus jedoch nicht abzuleiten, dass Anforderungen nachrangig werden.

Anforderungen bleiben der Ausdruck fachlicher Absicht. Sie beantworten Fragen wie: Welches Problem soll gelöst werden? Welche Entscheidung soll unterstützt werden? Welche Wirkung ist erwünscht? Welche Risiken sind akzeptabel? Welche Kontrolle muss beim Menschen bleiben? Welche regulatorischen, organisatorischen oder ethischen Grenzen gelten?

Daten wirken auf diese Absicht zurück. Sie können eine Anforderung ermöglichen, präzisieren, einschränken oder widerlegen. Ein Beispiel: Die fachliche Anforderung lautet, auffällige Transaktionen früher zu erkennen. Ob das möglich ist, hängt von verfügbaren Daten, Datenqualität, Labeling, Repräsentativität, historischen Verzerrungen, zulässiger Nutzung und Evaluationsmetriken ab. Die Datenlage entscheidet also mit, wie die Anforderung realistisch formuliert und abgenommen werden kann.

Position: Daten ersetzen keine Anforderungen. Sie werden zu einem Anforderungsartefakt erster Klasse. Was sich ändert, sind die Artefakte und ihre Verknüpfungen - nicht der Bedarf an fachlicher Struktur.

Aktuelle RE4AI-Literatur stützt diese Sicht. Systematic Mapping Studies zeigen, dass Requirements Engineering für KI-Systeme ein noch reifendes Feld ist und insbesondere Spezifikation, Erklärbarkeit, Datenanforderungen, Ethik, Vertrauen und die Lücke zwischen ML Engineers und End Usern weiterhin zentrale Herausforderungen darstellen [2][3].

4. Was neu gebraucht wird

Wenn Daten, Modelle und Evaluation Teil der Anforderungslage werden, braucht das Projekt neue Artefakte. Sie müssen nicht zwingend in einem neuen Werkzeug entstehen. Entscheidend ist, dass sie fachlich geführt, eindeutig verortet und mit der Anforderung verbunden werden.

1. **Datenquelle und Datenherkunft.** Es muss nachvollziehbar bleiben, welche Daten verwendet wurden, woher sie stammen, für welchen Zweck sie erhoben wurden und ob ihre Nutzung zulässig ist.
2. **Datenqualität und Repräsentativität.** Die Anforderung muss mit Aussagen zur Eignung der Daten verbunden werden: Vollständigkeit, Aktualität, Abdeckung, bekannte Lücken, Verzerrungen und Grenzen.
3. **Modellentscheidung.** Bei KI-Systemen wird die Entscheidungsebene wichtiger. Dokumentiert werden muss nicht nur, welches Modell verwendet wird, sondern warum Alternativen verworfen, Schwellenwerte gesetzt oder bestimmte Metriken akzeptiert wurden.
4. **Evaluationskriterien.** Akzeptanzkriterien müssen fachliche Gütemaße enthalten: Mindestleistung, tolerierbare Fehler, False Positives/False Negatives, Robustheit, Erklärbarkeit, menschliche Übersteuerbarkeit und Einsatzgrenzen.
5. **Test- und Evaluationsdaten.** Training, Validierung, Test und produktive Beobachtung dürfen nicht vermischt werden. Welche Daten wofür verwendet wurden, muss nachvollziehbar bleiben.
6. **Monitoring und Drift-Beobachtung.** Nach dem Go-live muss beobachtet werden, ob Modellleistung, Datenbasis oder Nutzungskontext sich verändern. Diese Beobachtung ist kein Betriebsanhang, sondern Teil der fachlichen Zusage.
7. **Produktionsnachweis.** Für regulierte Umfelder reicht es nicht, eine Modellversion produktiv zu setzen. Es muss nachvollziehbar bleiben, welche fachliche Anforderung mit welchem Datenstand, welcher Modellversion, welcher Evaluation und welcher Abnahme produktiv wirksam wurde.

5. Informationsarchitektur statt Dokumentenarchäologie

Viele Organisationen werden versuchen, die neuen Nachweisanforderungen durch zusätzliche Dokumente zu beantworten. Das ist verständlich, löst aber das Grundproblem nicht. Wenn Datenbeschreibung, Modellbewertung, Risikoentscheidung, Akzeptanzkriterium, Testnachweis und Monitoringbericht getrennt geführt werden, entsteht erneut Fragmentierung.

Informationsarchitektur bedeutet deshalb nicht, mehr Dokumente zu erzeugen. Sie bedeutet, fachliche Informationen so zu strukturieren, dass jede Information genau einen Ort hat und jede Ebene genau eine Frage beantwortet. Dokumente sind dann Sichten auf geführte Information, nicht deren führende Form.

Für KI-gestützte Systeme ist diese Unterscheidung entscheidend. Ein Datasheet for Datasets kann beschreiben, welche Daten verwendet werden und welche Grenzen sie haben [4]. Eine Model Card kann Leistungen, Einsatzbereiche und Grenzen eines Modells dokumentieren [5]. Beide Formate sind wertvolle Bausteine. Sie ersetzen aber nicht die fachliche Klammer. Erst die Verbindung mit Business Need, Anforderung, Entscheidung, Akzeptanzkriterium, Test, Abnahme und Produktion macht daraus nachvollziehbares Projektwissen.

Nicht das einzelne Dokument schafft Nachvollziehbarkeit. Nachvollziehbarkeit entsteht durch die belastbare Verbindung der Informationen.

Am Beispiel von MORE® lässt sich diese Logik so beschreiben: Die fachliche Ordnung beginnt nicht beim Tool und nicht beim Dokument, sondern beim Anwendungsfall. Dort werden Bedarf, Modelle, Regeln, Datenbezug, Entscheidungen, Tests, Abnahmen und Nachweise zusammengeführt oder eindeutig verknüpft. Die Struktur bleibt methodenneutral. Sie kann agile, klassische oder hybride Vorgehensweisen unterstützen.

Damit kommt auch das Konfigurationsmanagement wieder ins Spiel. Bei KI-gestützten Systemen ist nicht nur die eingesetzte Softwareversion konfigurationsrelevant. Zur fachlich wirksamen Konfiguration gehören ebenso Datenstand, Datensatzversion, Modellversion, Modellparameter, Prompt, Schwellenwert, Evaluationsset, Monitoringregel und produktive Betriebsumgebung.

Klassisches Konfigurationsmanagement beantwortet häufig die Frage, welche Code- oder Systemversion zu einem bestimmten Zeitpunkt produktiv war. Für KI-Systeme reicht diese Frage nicht mehr aus. Entscheidend ist, welche fachliche Zusage mit welcher Daten-, Modell- und Systemkonfiguration produktiv eingelöst wurde. Nur dann lässt sich später nachvollziehen, warum ein bestimmtes Ergebnis erzeugt, akzeptiert oder verworfen wurde.

KI erweitert Konfigurationsmanagement vom technischen Versionsnachweis zum fachlichen Nachweis der Systemwirkung.

Für die Informationsarchitektur bedeutet das: Konfigurationsmanagement darf nicht neben der Anforderung laufen. Es muss mit dem fachlichen Geschäftsbedarf, der Anforderung, der Datenquelle, der Datenqualität, der Modellentscheidung, den Akzeptanzkriterien, der Evaluation, der Abnahme und dem Produktionsnachweis verbunden sein. Erst diese Verbindung macht erklärbar, welche Konfiguration für welche fachliche Wirkung verantwortlich war.

6. Regulatorischer Anschluss

Die regulatorische Entwicklung bestätigt diese Richtung. Die KI-Verordnung der Europäischen Union verlangt für Hochrisiko-KI-Systeme unter anderem Daten-Governance- und Datenmanagementverfahren für Trainings-, Validierungs- und Testdatensätze, technische Dokumentation sowie Aufzeichnungspflichten [6]. Diese Anforderungen lassen sich nicht belastbar am Ende eines Projekts rekonstruieren. Die Verbindung von Datensatz, Modellversion, fachlicher Entscheidung und Nachweis muss während der Arbeit entstehen.

ISO/IEC 42001:2023 beschreibt Anforderungen an ein Managementsystem für künstliche Intelligenz und adressiert Aufbau, Umsetzung, Pflege und kontinuierliche Verbesserung eines AI Management Systems [7]. Das NIST AI Risk Management Framework bietet einen Risikorahmen für Organisationen, die KI-Systeme entwerfen, entwickeln, einsetzen oder nutzen [8].

Beide Ansätze sind auf Management- und Governance-Ebene wertvoll. Sie beantworten aber nicht automatisch, wo im Projekt eine fachliche Entscheidung, ein Datenqualitätsbefund, ein Evaluationskriterium oder ein Produktionsnachweis abgelegt und mit der Anforderung verbunden wird.

Genau hier liegt die operative Lücke.

Governance gibt den Anspruch vor.

Informationsarchitektur setzt ihn in der Projektarbeit um.

7. Praktische Empfehlungen

Für die praktische Arbeit ergeben sich daraus sieben Empfehlungen.

1. **Nicht mit dem Tool beginnen.** Zuerst muss klar sein, welche Information welche Frage beantwortet. Erst danach ist zu entscheiden, welches Werkzeug diese Struktur trägt.
2. **Daten als eigenes Anforderungsartefakt führen.** Datenquelle, Herkunft, Qualität, Repräsentativität, Nutzungsrechte und bekannte Grenzen gehören zur Anforderungslage.
3. **Akzeptanzkriterien erweitern.** Bei KI-Systemen reichen funktionale Kriterien nicht aus. Benötigt werden fachliche Gütemaße, Fehlergrenzen, Einsatzgrenzen, Erklärbarkeit und menschliche Kontrollpunkte.
4. **Entscheidungen dort dokumentieren, wo sie wirken.** Warum ein Datensatz, ein Modell, eine Schwelle oder eine Metrik gewählt wurde, gehört an den fachlichen Kontext, nicht nur in ein Protokoll.
5. **Training, Validierung, Test und Monitoring trennen.** Die Nachvollziehbarkeit der verwendeten Datenstände ist eine Grundvoraussetzung für belastbare Evaluation und spätere Prüfung.
6. **Abnahme nicht als Endpunkt verstehen.** Bei KI-Systemen ist Abnahme ein Zustand, der durch Monitoring, Drift-Erkennung und erneute Bewertung gehalten werden muss.
7. **Nachweisfähigkeit während der Arbeit prüfen.** Die zentrale Kontrollfrage lautet: Können wir heute erklären, welcher fachliche Bedarf mit welchen Daten, welchem Modell, welcher Evaluation und welcher Entscheidung produktiv wirksam ist?

8. Der Kreis schließt sich: Agilität, Regulierung, KI

KI macht die agile Arbeitsweise nicht überflüssig. Sie macht deutlich, ob ein Unternehmen Agilität wirklich verstanden hat. Agilität war nie nur Sprint, Daily, Board und Velocity. Agilität ist die Fähigkeit einer Organisation, unter Unsicherheit zu lernen, Entscheidungen zu treffen und dieses Lernen schnell in wirksame Produktentwicklung zu übersetzen.

Genau diese Fähigkeit ist für KI-gestützte Systeme Voraussetzung. Daten müssen geprüft, Hypothesen getestet, Modelle bewertet, Rückmeldungen aufgenommen und fachliche Entscheidungen iterativ angepasst werden. Gleichzeitig steigen Nachweislast, Regulatorik und Verantwortung.

Agile 1.0: iterativ Software liefern.

Agile im regulierten Umfeld: iterativ liefern und nachvollziehbar bleiben.

Agile für KI: iterativ lernen, datenbasiert entwickeln, regulatorisch nachweisen und produktiv überwachen.

Jede Stufe baut auf der vorherigen auf. Sie erweitert sie um einen Anspruch. Nicht die Methode wird zwingend schwerer, die Nachweislast wird es.

Wer Agilität nur als Ritual verstanden hat, wird bei KI scheitern.

Wer Agilität als Lern- und Entscheidungsfähigkeit versteht, braucht dafür eine Informationsarchitektur, die dieses Lernen dauerhaft nachvollziehbar macht.

Agilität ohne Informationsarchitektur skaliert in KI-Projekten nicht. Sie beschleunigt nur den Wissensverlust.

9. Fazit

KI verschiebt Requirements Engineering von der reinen Beschreibung gewünschter Funktionen hin zur Führung eines fachlich-technischen Nachweissystems. Anforderungen bleiben der Ausdruck fachlicher Absicht. Daten, Modelle, Evaluationen und Monitoring werden zu zusätzlichen Artefakten, die diese Absicht begrenzen, präzisieren und belegen.

Die zentrale Herausforderung liegt deshalb nicht darin, noch mehr Dokumente zu erzeugen. Sie liegt darin, eine Informationsarchitektur zu schaffen, in der Business Need, Anforderung, Datenbasis, Modellentscheidung, Akzeptanzkriterium, Test, Abnahme, Release und Produktionsnachweis dauerhaft verbunden bleiben.

Damit wird Informationsarchitektur zu einer Kernfähigkeit moderner Projekte. In klassischen Projekten reduziert sie Rekonstruktion. In regulierten Projekten schafft sie Nachvollziehbarkeit. In KI-gestützten Projekten entscheidet sie darüber, ob ein System später erklärbar, prüfbar und verantwortbar bleibt.

Die Dokumentation entsteht nicht nachträglich. Sie entsteht während der Arbeit an der Anforderung.

Literatur und Quellen

- [1] Vogelsang, A.; Borg, M.: Requirements Engineering for Machine Learning: Perspectives from Data Scientists. IEEE REW, 2019. DOI: 10.1109/REW.2019.00050.
- [2] Ahmad, K.; Abdelrazek, M.; Arora, C.; Bano, M.; Grundy, J.: Requirements Engineering for Artificial Intelligence Systems: A Systematic Mapping Study. Information and Software Technology 158, 2023, 107176. DOI: 10.1016/j.infsof.2023.107176.
- [3] Habiba, U. E.; Haug, M.; Bogner, J.; Wagner, S.: How mature is requirements engineering for AI-based systems? Requirements Engineering 29, 2024, S. 567-600. DOI: 10.1007/s00766-024-00432-3.
- [4] Gebru, T. et al.: Datasheets for Datasets. Communications of the ACM 64(12), 2021, S. 86-92.
- [5] Mitchell, M. et al.: Model Cards for Model Reporting. FAT* 2019, S. 220-229.
- [6] Verordnung (EU) 2024/1689 (KI-Verordnung), insbesondere Art. 10 Daten und Data Governance, Art. 11 Technische Dokumentation und Art. 12 Aufzeichnungspflichten.
- [7] ISO/IEC 42001:2023: Information technology - Artificial intelligence - Management system.
- [8] NIST: Artificial Intelligence Risk Management Framework (AI RMF 1.0), NIST AI 100-1, 2023.

www.more-framework.org · mail@more-framework.org
www.projektkram.de · hallo@projektkram.de