

KI-Expertensysteme in der Produktentwicklung als Chance für die Konservierung von wertvollem Expertenwissen und nachhaltigerer Ressourcenplanung

Dr.-Ing. Dirk Rensink
SEGULA Technologies

Dipl.-Ing. Lars-Christian Bütow, Mareike Keil (M.Sc.)
SEGULA Technologies AG

1 Motivation

System Design und Optimierung der Produktentwicklung sind vor allem in der Automotive-Branche stark abhängig von Expertenwissen, welches durch zunehmenden Fachkräftemangel immer wertvoller wird. Viele Unternehmen lassen zudem im Hinblick auf Kostenersparnis und Ressourcenengpass möglichst viele Aufgaben von kostengünstigeren und daher meist unerfahrenen Ingenieuren erledigen. Daher müssen Seniorexperten ihre realen, praktischen Erfahrungen an die jungen Entwicklungsingenieure übermitteln können. Dies gewährleistet die Wettbewerbsfähigkeit der Hersteller und Zulieferer und sichert die Qualität der Ergebnisse. Des Weiteren resultieren die zunehmende Digitalisierung und Globalisierung in einer immer größeren Datenmenge, die während der Produktentwicklung erzeugt wird. Jedoch liegen diese Daten meist an verschiedenen Orten in unterschiedlichen und zum Teil nur in menschenlesbaren Formaten vor. Diese distributive Verwaltung der Daten, sowie die Arbeitsweise auf Distanz haben zur Folge, dass keine konsolidierten Daten vorliegen und somit kein Single-Point-Of-Truth (SPOT) existiert.

Das Forschungsprojekt „Entwicklungsplattform 4.0“ widmet sich den oben aufgeführten Herausforderungen. Innerhalb dieses Projekts wird ein KI-Expertensystem aufgebaut, das u.a. Test- und Simulationsdaten miteinander verknüpft und hierdurch einen SPOT schafft.

In diesem Beitrag wird zunächst auf KI-Expertensysteme sowie deren Nutzung allgemein eingegangen. Anschließend erfolgt eine kurze Vorstellung des Forschungsprojekts „Entwicklungsplattform 4.0“ sowie die Präsentation der Wissensdatenbank und des WikiBots, die der Konservierung und Bereitstellung des Expertenwissens dienen. Zum Schluss werden noch zukünftige Potenziale und Entwicklungsmöglichkeiten hervorgehoben.

2 KI-Expertensysteme

KI-Expertensysteme stellen eine spezielle Art von Künstlicher Intelligenz (KI) dar, die mit dem Ziel entwickelt wurden, menschenähnliche Entscheidungen auf einem bestimmten Fachgebiet zu treffen und komplexe Probleme zu lösen [1]. Sowohl die Entscheidungsfindung als auch die Problemlösung dieser Systeme basieren auf einer Kombination von Daten, Algorithmen und menschlichem Fachwissen. Im Wesentlichen versuchen sie, das Wissen, die Erfahrung und die Entscheidungsprozesse eines menschlichen Experten zu modellieren, zu interpretieren und nachzuahmen.

KI-Expertensysteme bestehen im Allgemeinen aus nachfolgenden Komponenten (siehe Abb. 1):

- **Wissensbasis (Knowledge Base):** Enthält das Fachwissen von Experten, welches in Form von Regeln, Heuristiken und Fallbeispielen gespeichert ist und dient als Referenz für die Entscheidungsfindung.
- **Inferenzmaschine (Inference Engine):** Verwendet das Wissen aus der Wissensbasis sowie Algorithmen, um Schlussfolgerungen zu ziehen bzw. Probleme zu lösen.
- **Interaktive Benutzerschnittstelle (User Interface):** Ermöglicht die Interaktion zwischen Nutzer und System.
- **Erklärungskomponente:** Erklärt dem Anwender die Schlussfolgerung, z.B. anhand der zugrundeliegenden Regeln.
- **Wissenserwerbskomponente:** Extrahiert das Fachwissen von menschlichen Experten und bereitet es so auf, dass es vom Expertensystem genutzt werden kann.

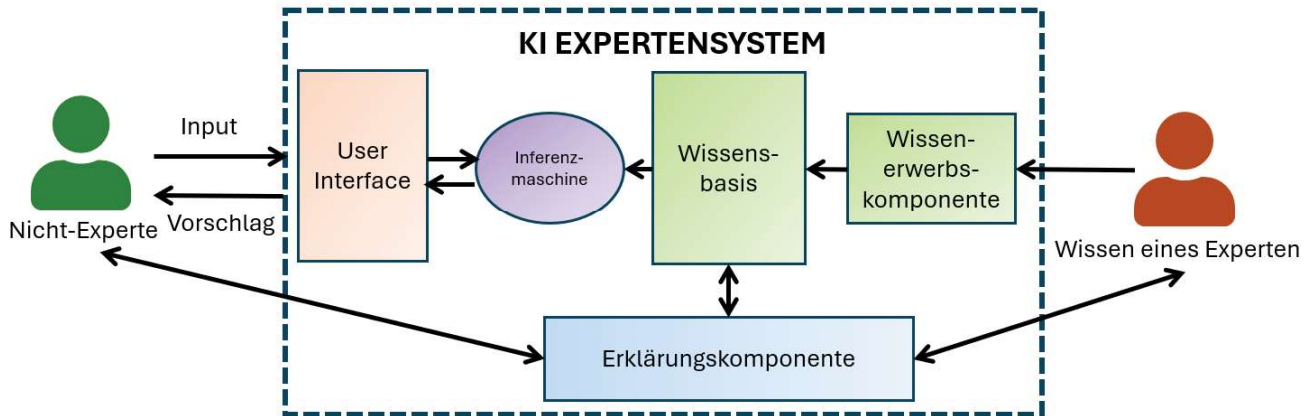


Abb 1: Aufbau eines KI-Expertensystems

Angemerkt sei hier, dass die Unterscheidung zwischen regelbasierten und selbstlernenden KI-Expertensystemen vorteilhaft ist. Diese beiden Formen weisen grundlegend verschiedene Ansätze zur Problemlösung und zur Informationsverarbeitung auf. Während regelbasierte Expertensysteme explizite Regeln für die Entscheidungsfindung und Problemlösung verwenden, die von menschlichen Experten zum Beispiel in Form einer Ontologie erstellt werden, basieren selbstlernende Expertensysteme auf Algorithmen des maschinellen Lernens, um aus Daten zu lernen und ihre Leistung im Laufe der Zeit zu verbessern. Sie kommen ohne explizite Regeln von menschlichen Experten aus. Die Regeln bei regelbasierten Expertensystemen werden in Form von "Wenn-Dann"-Anweisungen definiert, die angeben, welche Aktion in Abhängigkeit von bestimmten Bedingungen ausgeführt werden soll. Regelbasierte Expertensysteme gelten als transparent und nachvollziehbar, da die Entscheidungslogik durch die expliziten Regeln klar definiert ist. Selbstlernende Expertensysteme hingegen analysieren große Mengen von Daten, identifizieren Muster und treffen Entscheidungen auf Basis dieser Muster. Sie gelten daher als flexibel und können sich an veränderte Umstände und neue Daten anpassen. Aufgrund ihrer komplexen internen Strukturen sind sie allerdings undurchsichtiger als regelbasierte Expertensysteme.

Ein bekanntes Beispiel für ein regelbasiertes KI-Expertensystem ist das Deep Blue-System von IBM [2], das für das Schachspielen entwickelt wurde. Deep Blue setzte eine Vielzahl von Techniken ein, darunter speziell entwickelte Hardware, um Schachzüge zu berechnen und Entscheidungen zu treffen, die denen eines menschlichen Schachgroßmeisters ähneln. Hierdurch gelang es Deep Blue, den damals amtierenden Schachweltmeister Garri Kasparov zu besiegen. Da Deep Blue auf vordefinierten Strategien und Algorithmen basierte und das System nicht in der Lage war, aus neuen Informationen zu lernen, zählt es zu den regelbasierten KI-Expertensystemen.

Ein Beispiel für ein selbstlernendes KI-Expertensystem ist das von Google DeepMind (früher DeepMind Technologies) entwickelte Computerprogramm AlphaGo, welches den amtierenden Weltmeister Lee Sedol geschlagen hat. AlphaGo verwendet nicht das Wissen von Experten bzw. von diesen definierte Regeln als Wissensbasis, sondern maschinelles Lernen und tiefe neuronale Netze, um auf Basis von großen Datenmengen und Mustererkennung in Spielzügen das Spiel Go zu erlernen. Daher zählt es zu den selbstlernenden KI-Expertensystemen.

KI-Expertensysteme kommen in vielen Bereichen wie Medizin und Produktentwicklung zum Einsatz. In der Medizin werden sie z.B. zur Diagnose von Krankheiten verwendet [3] und in der Fertigung z.B. für die Qualitätskontrolle und Prozessoptimierung [4].

3 Konservierung von Expertenwissen

3.1 Entwicklungsplattform 4.0

Das durch den BMWK-geförderte Forschungsprojekt „Entwicklungsplattform 4.0“ beschäftigt sich neben einer Verbesserung der Effizienz und Qualität in der Produktentwicklung auch mit einer umfassenden Unterstützung von Junior-Ingenieuren sowie mit der Erhaltung und Bereitstellung von (Simulation- und Test-) Senior-Expertenwissen. Diese ambitionierten Ziele werden durch eine Vernetzung der Simulations- und Testdatenmanagement Welt und der damit verbundenen Ressourceneinsparung erreicht sowie durch den Einsatz eines WikiBots, um den Anwendern einen benutzerfreundlichen und zielführenden Zugriff auf wertvolles Expertenwissen zu bieten [5]. Um entsprechende Wissensquellen dem Wikibot zur Verfügung zu stellen, wurde neben der Wissensdatenbank (siehe 3.3) auch ein funktionaler Prototyp eines Prozessbegleiters implementiert. Der Prozessbegleiter fungiert als Schnittstelle zwischen Prozess und Wissensdatenbank. Er führt während der Simulation durch den CAE-Kernprozess, stellt über geeignete Schnittstellen zur Wissensdatenbank gezielt Informationen für den jeweiligen Prozessschritt zur Verfügung und speichert relevante Informationen aus den einzelnen Phasen des Simulationprozesses für eine spätere Performance-Auswertung (siehe Abb. 2).

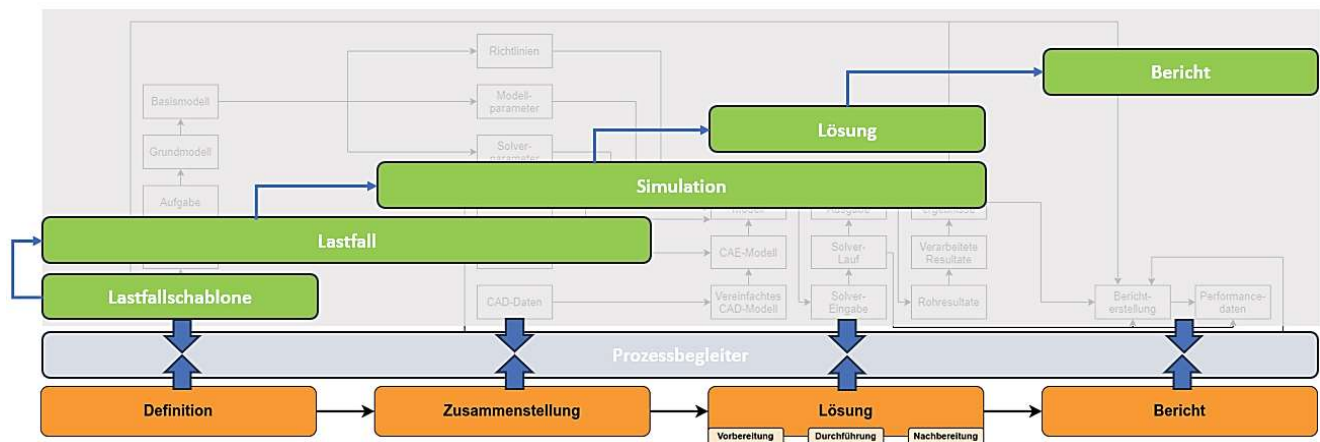


Abb 2: Einbettung des Prozessbegleiters in den Simulationsprozess

Mit Abb. 3 wird gezeigt, welche Artefakte in welcher Phase relevant sind, und damit wird auch eine Übersicht über die im Prozessbegleiter hinterlegten Informationen gegeben.

Die Phasen *Definition*, *Zusammenstellung*, *Lösung* und *Bericht* sind dabei wie folgt zu verstehen:

- **Definition:** Definition der Aufgabe mit einer möglichst genauen Beschreibung der Inhalte und der zu berichtenden Ergebnisse
- **Zusammenstellung:** Sammlung aller zur Aufgabenstellung notwendigen Daten
- **Lösung:** Lösung der Aufgabenstellung
- **Bericht:** Erstellung des Berichts, Reflexion für das Qualitätsmanagement

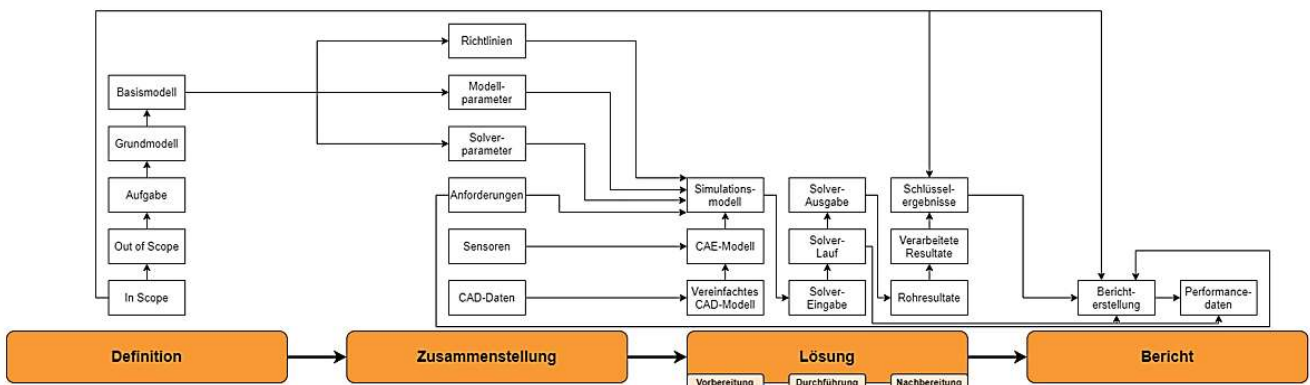


Abb. 3: Artefakte innerhalb der Phasen des Simulationsprozesses

3.2 Ontologie

Die Inferenzmaschine ist, wie bereits vorher erwähnt, ein elementarer Bestandteil des KI-Expertensystems. Damit diese ihre Aufgabe zuverlässig und zielführend erfüllen kann, ist es essenziell, dass eine Ontologie als Basis zur Ableitung der Inferenzregeln vollständig und umfänglich ausgearbeitet wird. Der Entwicklungsprozess einer solchen Ontologie umfasst üblicherweise 5 Stufen (siehe Abb. 4):

- **Stufe 1:** Erstellung eines Glossars
- **Stufe 2:** Aufbau einer Taxonomie
- **Stufe 3:** Erstellung eines Thesaurus
- **Stufe 4:** Aufbau eines semantischen Netzes
- **Stufe 5:** Aufbau einer Ontologie



Abb. 4: Schritte im Ontologie-Entwicklungsprozess

Sowohl der Aufbau als auch die Pflege der Ontologie sind integraler Bestandteil des Wissensmanagements. Eine gut gepflegte Ontologie stellt sicher, dass das Wissen innerhalb des Systems strukturiert und leicht zugänglich bleibt, was für die Effizienz und Zuverlässigkeit des KI-Expertensystems von entscheidender Bedeutung ist.

Die im Rahmen des Forschungsprojekts entwickelte Ontologie basiert auf dem Kernprozess für CAE (Computer-Aided Engineering) und Testing. Darüber hinaus wurde eine physikalische Kategorisierung berücksichtigt, um die Genauigkeit und Anwendbarkeit der Ontologie in realen Szenarien zu erhöhen (siehe Abb. 5). Diese Kategorisierung ermöglicht eine präzisere Modellierung physikalischer Prozesse und Phänomene, was wiederum die Qualität der Inferenz und die Entscheidungsfindung des Systems verbessert.

Discipline	Behaviour	Complexity	Thermodynamics	Time Dependency	Specific 1	Specific 2	Specific 3
Fluid	Incompressible	Laminar	Isothermal	Stationary	Number Phases	Species	Acoustics
	Compressible	Turbulent	Non-Isothermal	Transient			
Strcuture	Elastic	Linear	Isothermal	Stationary	Contacts	Connections	Acoustics
	Plastic	Nonlinear	Non-Isothermal	Transient			
Multibody	Elastic	Cinematic	Isothermal	Stationary	Contacts	Connections	Acoustics
	Plastic	Dynamic	Non-Isothermal	Transient			

Abb. 5: Physikalische Kategorisierung als Grundlage für die Ontologie

Zusätzlich zur physikalischen Kategorisierung wurden auch verschiedene Domänenexperten eingebunden, um sicherzustellen, dass die Ontologie alle relevanten Aspekte abdeckt und praxisnah ist. Die regelmäßige Überprüfung und Aktualisierung der Ontologie gewährleistet, dass sie mit den neuesten Erkenntnissen und technologischen Entwicklungen Schritt hält.

Durch diese umfassende und sorgfältige Vorgehensweise wird sichergestellt, dass die Ontologie nicht nur theoretisch fundiert, sondern auch praktisch anwendbar ist, was die Gesamtleistung des KI-Expertensystems maßgeblich steigert.

3.3 Wissensdatenbank und WikiBot

Die Implementierung einer Wissensdatenbank und eines WikiBots und die damit verbundene Konservierung von Expertenwissen sowie dessen zur Verfügungstellung führen zukünftig zu einer Effizienzsteigerung und Entwicklungszeitverkürzung. Durch den Aufbau einer Wissensdatenbank und die Nutzung des WikiBots, können Junior-Ingenieure auf Erfahrungswerte von Senior-Ingenieuren zu jeder Zeit zugreifen und ihr Wissen erweitern sowie Aufgaben zielführender und schneller erledigen. Zudem wird das Risiko von fehlerhaften bzw. unvollständigen Parametersätzen und Einstellungen bei Tests und Simulationen reduziert. Darüber hinaus wird die Anzahl der Tests und Simulationen minimiert, wenn auf entsprechende Erfahrungswerte zugegriffen werden kann.

Um die aufgeführten Vorteile zu erreichen, erfassen Senior-Ingenieure ihr Wissen über Simulationen und Tests in einem betriebsinternen Expertensystem – der Entwicklungsplattform 4.0. Diese Plattform kann durch Junior-Ingenieure genutzt und ggf. eigenständig nach erfolgter Freigabe durch das Qualitätsmanagement ergänzt werden. Die Erfassung erfolgt hierbei in einer lokalen Wissensdatenbank, so dass die Daten und die wertvoll gesammelten Erfahrungswerte nicht unerwünscht verbreitet werden können und der Cyberschutz gewährleistet ist. Der schnelle Zugriff auf dieses Wissen wird durch einen lokalen WikiBot ermöglicht. An jeder Stelle im Expertensystem hat der Anwender die Möglichkeit den WikiBot aufzurufen und seine Frage zu stellen (siehe Abb. 6). Darüber hinaus existiert eine eigene WikiBot-Seite im System, in dem ähnlich zu ChatGPT alte Anfragen gespeichert werden (siehe Abb. 7).

Der WikiBot filtert basierend auf der Anfrage des Anwenders die Wissensdatenbank nach den gewünschten Informationen, stellt diese dem Nutzer zur Verfügung und interpretiert die Ergebnisse ggf. Dies verkürzt den Arbeitsprozess ungemein, da der für die Aufgabe zuständige Ingenieur nicht viele verschiedene Datenbanken nach den Informationen selbst durchsuchen und nicht passende Ansprechpartner identifizieren und auf deren Rückmeldung warten muss.

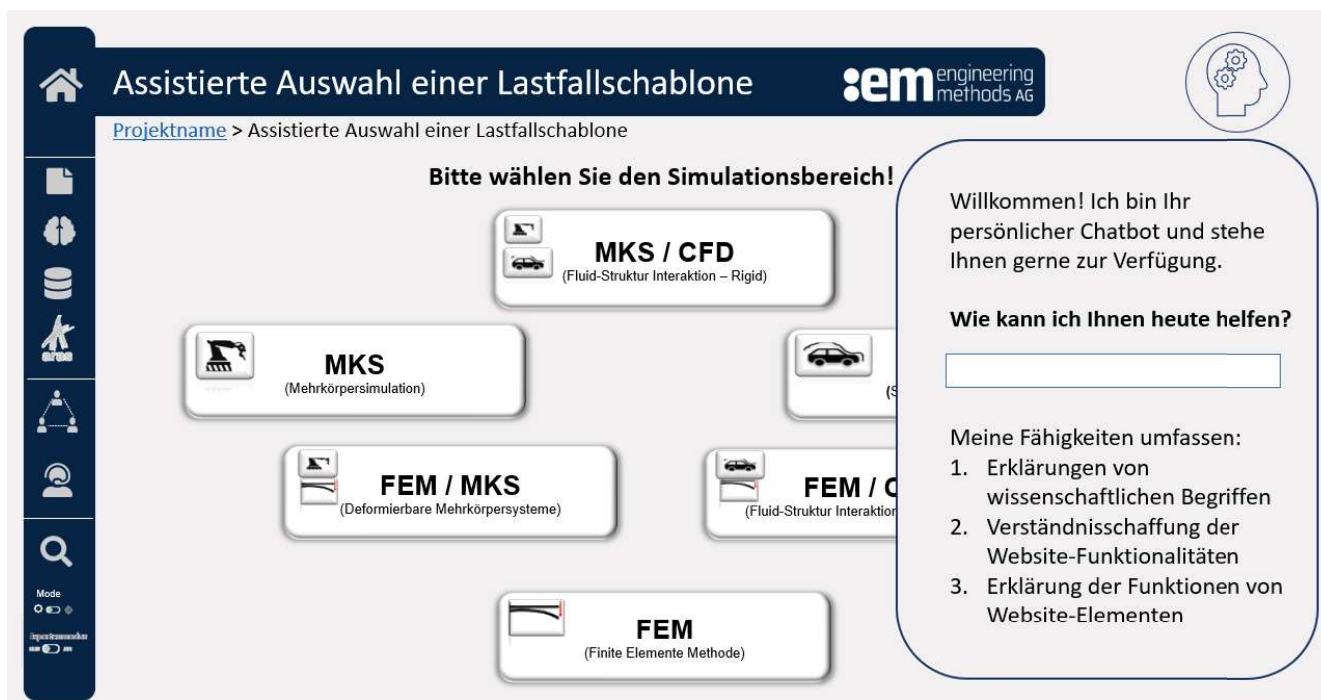


Abb. 6: Zugriff auf den WikiBot zu jeder Zeit im System

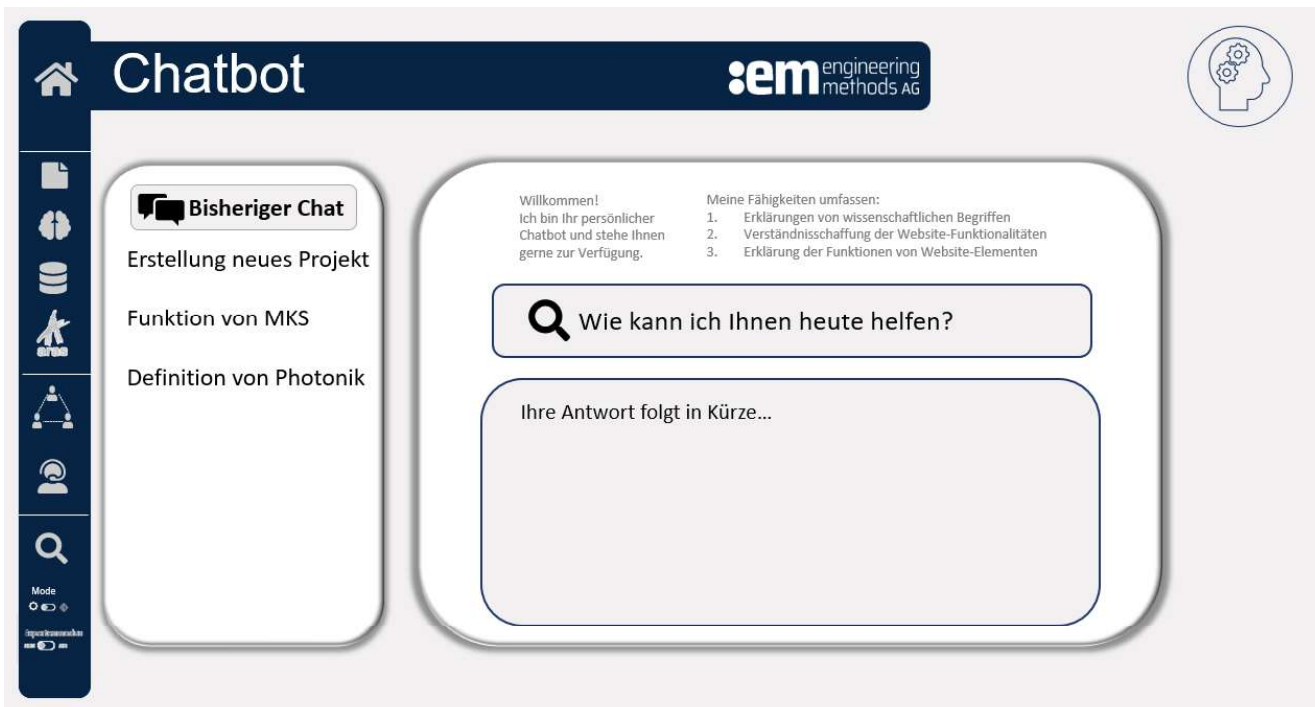


Abb. 7: WikiBot Übersichtsseite mit gespeicherten Anfragen

3.4 Implementierung des WikiBots

Aufgrund geltender Sicherheitsvorschriften und Regelungen, wie beispielsweise TISAX, sowie der Notwendigkeit der Gewährleistung der Kundendatensicherheit, ist die Integration bestehender und damit globaler Chatbots (z. B. ChatGPT) nicht möglich [6]. Durch die Implementierung eines eigenen, lokalen Chatbots für die Entwicklungsplattform, wird eine unerwünschte Verbreitung der gespeicherten Daten verhindert. Dieses Modell wird ausschließlich mit den dem Unternehmen zur Verfügung stehenden Daten trainiert und hat auch nur auf diese Daten Zugriff. Eine Möglichkeit zur Kommunikation mit externen Systemen oder eine Internetverbindung besteht nicht.

Im Rahmen des Forschungsprojekts fand das OpenSource Sprachmodell BERT (Bidirectional Encoder Representations from Transformers) von Google [7, pp. 64-66] Anwendung und wurde an die projektspezifischen Anforderungen mittels Fine-Tuning [8] angepasst und gespeichert (siehe Abb. 8). Ziel des Modells ist es nicht nur, von Menschen formulierte Fragen besser zu verstehen, sondern auch die spezifische „Anwendersprache“ zu verarbeiten. Dies schafft ein menschlicheres Nutzererlebnis, da der Chatbot wie ein Kollege interagiert. Dadurch bietet BERT die Möglichkeit, Suchergebnisse anzuzeigen, die die eingegebene Frage am zielführendsten beantworten. Eine detailliertere Beschreibung findet sich in [9].

BERT wurde als vortrainiertes Sprachmodell ausgewählt, weil es den Inhalt und die Bedeutung einzelner Wörter im Gesamtkontext von Suchanfragen erfasst [7, pp. 66-67]. Mittels Fine-Tuning wurde das Modell auf den spezifischen Anwendungsfall angepasst. Dieser erforderte innerhalb des Forschungsprojekts, dass ein eingegebener Satz oder eine eingegebene Frage auf einen Suchbegriff abgebildet wird, der in einer Datenbank gefunden werden kann. Dafür wurde ein Datensatz verwendet, der aus Fragen und den dazugehörigen Suchbegriffen - den „Antworten“ - bestand. Diese Aufgabe ist als Sentence Classification Task bekannt, bei der ein Text auf eine bestimmte Kategorie abgebildet wird. Die Auswahl von BERT wurde dadurch validiert, dass bereits nach wenigen Trainingsiterationen auf dem Validierungsdatensatz eine Genauigkeit von 96% erzielt werden konnte.

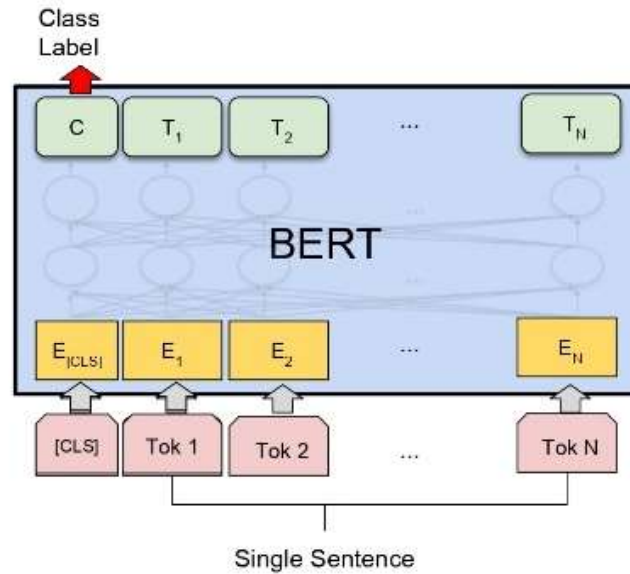


Abb. 8: Illustration von Bert Fine-Tuning [9]

Für die Umsetzung dieses Verfahrens wurde ein Datensatz mit ca. 1500 Datenpunkten verwendet. Das Modell wurde über 8 Epochen mit einer Batch Size von 32 und mithilfe des Adam-Optimizer trainiert [10]. Ein weiterer Linear Layer (<https://rentreuwang.github.io/learning-machine/layers/linear/linear.html>) wurde darüber hinaus hinzugefügt, wodurch die Abbildung des ursprünglichen Inputs auf die Klassen ermöglicht wird.

Das im Backend hinterlegte, gespeicherte und angepasste Modell ist mit einer entsprechenden API verknüpft. Erfolgt durch den Nutzer eine Eingabe einer Frage in natürlicher Sprache im Frontend, wird diese mittels Tokenizer vektorisiert (Umwandlung in reellwertige Vektoren), um sie in eine maschinenlesbare Form zu bringen, und über die entsprechende API an das Modell übergeben. Die Wahrscheinlichkeiten werden durch das Modell mittels einer Aktivierungsfunktion (hier: Softmax) für alle Suchbegriffe, mit denen das Modell nachtrainiert wurde, berechnet, und das Modell gibt anschließend den Suchbegriff mit der höchsten Wahrscheinlichkeit über die PostgreSQL Python API an die Projektdatenbank weiter. Dies ist eine Abfrage auf der Datenbank, um den passenden Eintrag zu finden und diesem dem Nutzer als Antwort zu präsentieren.

Eine Beschreibung technischer Angaben und verwendeter Methoden, wie z.B. den Tokenizer, findet sich bei HuggingFace [8 und <https://huggingface.co/dbmdz/bert-base-german-cased>].

4 Limitierungen und Diskussion

Die Vorteile des implementierten Chatbots zeigen sich besonders in einer verknüpften SDM/TDM Welt, da hier eine Handlungsempfehlung erfolgen kann, welche die Arbeit der Ingenieure beschleunigt. Dies wird dadurch erzielt, dass vorgeschlagen wird, welche Simulationen und welche physischen Tests durchgeführt werden müssen. Hierfür greift der Chatbot auf die in einem PLM-System (hier: ARAS) hinterlegten Lastfälle zu. Über die Verknüpfung von Simulation und Test mittels Relationen [11] erfolgt eine Prüfung hinsichtlich der erfolgreichen Durchführung von Simulationen und Tests bei ähnlichen Projekten, wie dem vom Nutzer in den Chatbot eingegebenen. Zukünftig werden diese Informationen nicht nur dem Anwender übergeben, sondern diesem auch das weitere Vorgehen vorgeschlagen (siehe Abb. 9). Durch die Verwendung des Chatbots erspart sich der Nutzer jede mit dem passenden Lastfall verknüpfte Simulation und jeden verknüpften Test im PLM-System manuell durchzuschauen, mit dem aktuellen Projekt abzugleichen und zu interpretieren und daraus die nächsten Schritte abzuleiten. Neben der enormen Kostenreduktion resultiert dies auch in einer Risikominimierung, da die Fehlerquote durch den Faktor Mensch reduziert wird.

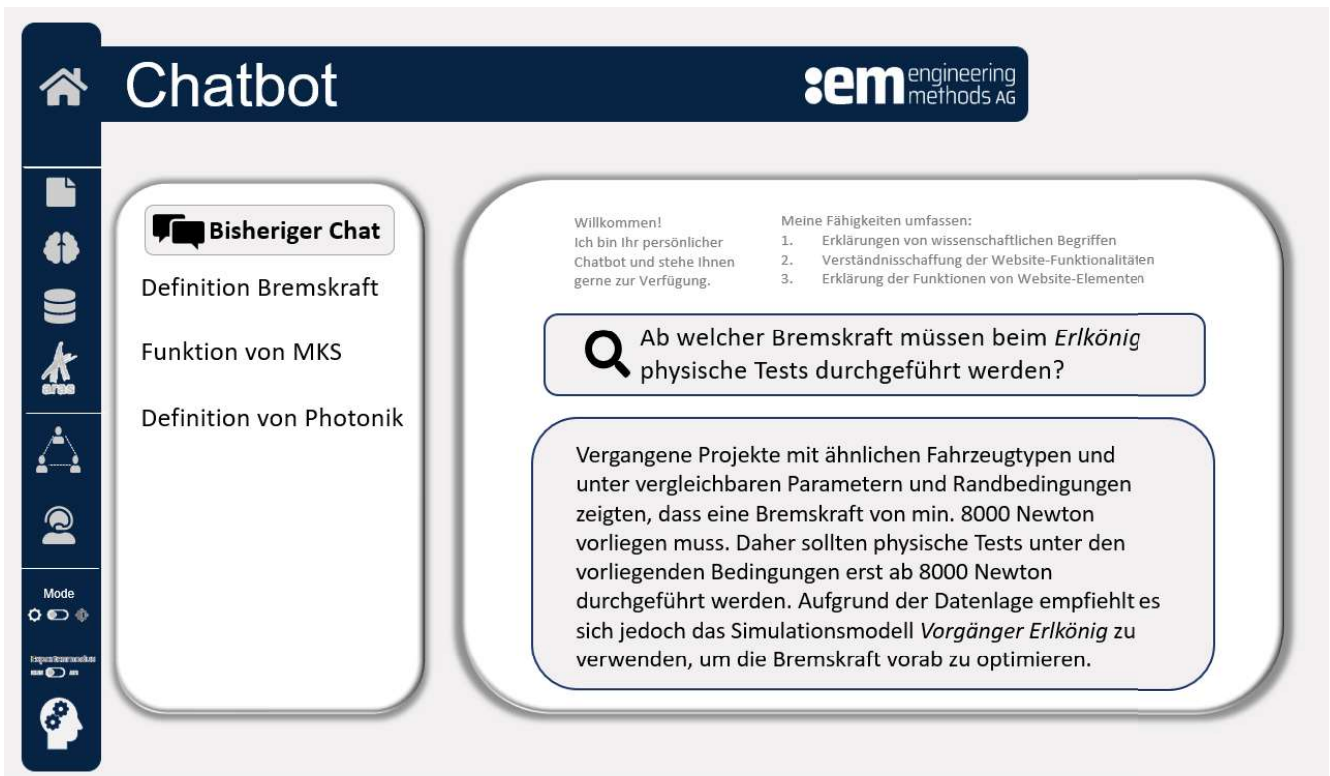


Abb. 9: Beispielhafte Eingabe in den Chatbot mit Handlungsempfehlung als Ausgabe

Trotz der Vorteile hinsichtlich Zeitersparnis, Kostenreduktion und Risikominimierung sind auch einige Limitierungen bezüglich der Implementierung zu erwähnen. Aktuell ermöglicht die Implementierung von BERT kein kontinuierliches Lernen, sondern ist lediglich ein statisches Modell. Allerdings besteht die Möglichkeit, das Modell entsprechend anzupassen, um dies zu ermöglichen. Neuere Transformer-Modelle konnten aufgrund von Einschränkungen in der Hardware nicht genutzt werden. Mutmaßlich würde mit diesen sogar mit noch weniger Daten ebenfalls zufriedenstellende Ergebnisse erzielt werden. Angaben und Aussagen von Sprachmodellen sind aufgrund der Tatsache, dass es sich bei diesen in erster Linie um „Wahrscheinlichkeitsmaschinen“ handelt, mit Vorsicht zu betrachten. Sprachmodelle bergen das Risiko, dass z. B. der Kontext missverstanden wird bzw. sogenannte Halluzinationen entstehen. Das Auftreten von Problematiken hinsichtlich ethischer Fragen ist bei diesem Anwendungsfall sowie aufgrund der einseitigen Kommunikation nicht zu erwarten. Trainiert wird das Modell nur mit einem Firmenpolitik-konformen Frage-/Antwortkatalog. Die eingegebene Frage wird darüber hinaus lediglich auf einen Suchbegriff (Keyword) abgebildet.

5 Zusammenfassung und Ausblick

Aufgrund des demografischen Wandels können wertvolles Expertenwissen und gemachte Erfahrungswerte nicht mehr ausreichend in den Unternehmen weitergegeben werden und gehen damit verloren. Um den nachfolgenden Generationen dennoch eine Möglichkeit zu bieten, zukünftig von diesem Wissen zu profitieren, wird im Rahmen des Forschungsprojekts „Entwicklungsplattform 4.0“ ein KI-Expertensystem aufgebaut, das das Fachwissen konserviert und für berechtigte Personen zugänglich macht. Hierfür wird eine Wissensdatenbank implementiert, in der unter anderem Erfahrungswerte gespeichert sind. Um eine zielführende und schnelle Bereitstellung der Daten zu gewährleisten, werden die Anwender durch einen WikiBot unterstützt. Dieser durchsucht zielgerichtet die Wissensdatenbank nach passenden Informationen, die der Beantwortung der gestellten Frage des Nutzers entsprechen, stellt diese übersichtlich aufbereitet zur Verfügung und interpretiert diese.

Zukünftig soll es möglich sein, dass der WikiBot zudem aus alten Projekten lernt und somit dem Anwender potenzielle Projektverzögerungen aufzeigen und entsprechende Handlungsempfehlungen geben kann.

In der Weiterentwicklung leistungsfähiger KI-Systeme zur Verarbeitung natürlicher Sprache (Natural Language Processing, NLP) spielt die Verbindung mit einem Expertensystem eine wichtige Rolle. Chatbots wie ChatGPT oder Gemini sind wie in den vorherigen Kapiteln beschrieben „Wahrscheinlichkeitsmaschinen“, die die semantische Bedeutung ihrer Ausgabe nicht verstehen. Im Gegensatz zu den Chatbots ist die Semantik in Form der Ontologie die Grundlage für Expertensysteme, mit denen aber die Verarbeitung der natürlichen Sprache wie bei heutigen Chatbots nicht darstellbar ist. Eine Verbindung beider Arten der Künstlichen Intelligenz kann helfen, die Vorteile beider Technologien zu nutzen. So können Chatbots relevante Stichwörter aus einer Anfrage extrahieren und eine Wissensabfrage für das Expertensystem formulieren. Die Antwort des Expertensystem kann der Chatbot in natürlicher Sprache formulieren, wobei die semantische Korrektheit durch die Einbeziehung des Expertensystems sichergestellt ist. Eine solche Verbindung ist Gegenstand aktueller Forschung [12].

6 Danksagung

Dieses Forschungs- und Entwicklungsprojekt wird durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) im Rahmen des Verbundprojekts „Aufbau einer Entwicklungsplattform 4.0 – EP 4.0“ gefördert (Förderkennzeichen 19I21020A) und zudem unterstützt durch den TÜV Rheinland Consulting GmbH, Projektträger Bodengebundene Verkehrstechnologien (PT Bvt) mit der Vereinbarung № 19 I 21020A (June 02, 2021). Dafür danken wir dem BMWK und dem TÜV Rheinland.

Träger:	BMWK
Fachprogramm:	Neue Fahrzeug- und Systemtechnologien
Schwerpunkt:	Künstliche Intelligenz als Schlüsseltechnologie für das Fahrzeug der Zukunft
Beteiligte Partner:	SEGULA Technologies, FKFS, :em AG, Fraunhofer IESE (UB)
Projektbeginn:	01.06.2021
Projektdauer:	3,5 Jahre

7 Literatur

- [1] Myers, W. (1986). Introduction to expert systems. *IEEE Intelligent Systems*, 1(01), 100-109.
- [2] Hsu, F. H. (2002). *Behind Deep Blue: Building the computer that defeated the world chess champion*. Princeton University Press.
- [3] Alugubelli, R. (2016). Exploratory study of artificial intelligence in healthcare. *International Journal of Innovations in Engineering Research and Technology*, 3(1), 1-10.
- [4] Pierre, K., Haneberg, A. G., Kwak, S., Peters, K. R., Hochegger, B., Sananmuang, T., ... & Forghani, R. (2023, April). Applications of artificial intelligence in the radiology roundtrip: process streamlining, workflow optimization, and beyond. In *Seminars in Roentgenology* (Vol. 58, No. 2, pp. 158-169). WB Saunders.
- [5] Vorhabensbeschreibung "Entwicklungsplattform 4.0". Konsortialteam des Forschungsprojekts (2021)
- [6] Toyota Deutschland, *Toyota Deutschland launcht Prototypen für KI-Anwendungen*. 2023. url: [Toyota Deutschland launcht Prototypen für KI-Anwendungen \(industrie.de\)](https://www.industrie.de/News/Toyota-Deutschland-launcht-Prototypen-fuer-KI-Anwendungen)
- [7] A. Gillhuber, G. Kauermann, & W. Hauner, *Künstliche Intelligenz und Data Science in Theorie und Praxis*. Berlin: Springer Spektrum. 2023.
- [8] D. Rothman, *Transformers for Natural Language Processing: Build, train, and fine-tune deep neural network architectures for NLP with Python, Hugging Face, and OpenAI's GPT-3, ChatGPT, and GPT-4*. Packt Publishing Ltd. 2022.
- [9] J. Devlin, M. W. Chang, K. Lee & K. Toutanova, Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805. 2018. doi: <https://doi.org/10.48550/arXiv.1810.04805>
- [10] D. P. Kingma & J. Ba, Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980. 2014. doi: <https://doi.org/10.48550/arXiv.1412.6980>
- [11] L.-C. Bütow, M. Keil & R. Kircher, Vernetzung der Test- und Simulationswelt in einem PLM-System zur Förderung einer nachhaltigeren Entwicklung (Forschungsprojekt EP 4.0). NAFEMS DACH Konferenz, 2024.
- [12] Bialkova, S.: *The Rise of AI User Applications*. Springer 2024. DOI: <https://doi.org/10.1007/978-3-031-56471-0>