

Beiträge aus den Instituten



1. IDEE – digital – souverän

Prof. Dr.-Ing. Andreas Schiffler, Fabienne Riesel M.A.,
Phillipp Seitz M.Sc., Prof. Dr.-Ing. Stefanie Retka

IDEE – Das Institut für Digital Engineering

Das **Institut für Digital Engineering (IDEE)** ist ein fakultätsübergreifendes Institut der THWS. Geprägt wird es durch dedizierte Forschungsprofessuren und ein forschungsstarkes Kollegium in den Themenfeldern des Ingenieurwesens im Kontext der Digitalisierung. Anwendungsorientierte Forschung sowie die enge Kooperation mit der regionalen Wirtschaft stehen dabei im Vordergrund. Das IDEE strukturiert sich dafür thematisch in Forschungsfelder. Diese decken die Bereiche Digitalisierung, Produktion, Mechanische Systeme bis hin zur Gründungsunterstützung ab. Mit dem Forschungsfeld Computational Science werden zunehmend auch der Einsatz und die Weiterentwicklung von KI-Algorithmen fokussiert.

Spezifische Anwendungsthemen werden in den Forschungsfeldern additive Fertigung metallischer Werkstoffe und intelligente Produktionssysteme bearbeitet. Schließlich dient das Feld Entrepreneurship und Innovation dazu, den unterstützenden Rahmen und ein Netzwerk zu bieten, um Potenziale frühzeitig zu erkennen und herausragende Ideen zu wirtschaftlichem Erfolg zu führen.

Lärm gezielt bekämpfen, genetischer Algorithmus und Finite-Elemente helfen

Akustik erforschen – Von der Schwingung zum Klang

Die Akustik befasst sich als interdisziplinäres Teilgebiet der Physik und Ingenieurwissenschaften mit der Entstehung, Ausbreitung und Wahrnehmung mechanischer Schwingungen in gasförmigen, flüssigen und festen Medien. Das Labor für Akustik und Strukturodynamik an der THWS adressiert diese Fragestellungen mit Schwerpunkt auf der messtechnischen Erfassung von Luft- und Körperschall im hörbaren Frequenzbereich in Kombination mit numerischer Simulation. Im Mittelpunkt stehen die physikalischen Mechanismen der Schall- und Vibrationsentstehung, die Charakterisierung von Ausbreitungsphänomenen sowie die Geräuschdetektion.

Die experimentelle Infrastruktur des Labors umfasst umfangreiches messtechnisches Equipment sowie einen nach DIN-Norm zertifizierten Halbraum, der definierte reflexionsarme Messbedingungen gewähr-

leistet und eine hohe Reproduzierbarkeit akustischer Untersuchungen sicherstellt. Auf dieser Grundlage werden anwendungsorientierte Forschungsprojekte realisiert, die grundlagennahe Fragestellungen mit ingenieurwissenschaftlichen Problemstellungen verknüpfen. Ein aktuelles Forschungsvorhaben widmet sich der numerisch gestützten Optimierung von Schalldämpfungsstrukturen.

Lärm als unterschätzte Belastung

Wer in einem lauten Büro arbeitet, kennt das Problem: Die Konzentration sinkt, die Fehlerquote steigt, und am Ende des Tages ist man erschöpfter als nach einem ruhigen Arbeitstag. Was sich wie ein individuelles Empfinden anfühlt, ist wissenschaftlich gut belegt. Innenraumlärm – also unerwünscht hohe Schallpegel in geschlossenen Räumen wie Büros, Lernräumen, Fahrzeugen oder Wohngebäuden – kann zu erhöhtem Blutdruck, chronischem Stress und deutlichen Einbußen bei der kognitiven Leistungsfähigkeit führen.

Mit zunehmender Urbanisierung wird dieses Problem größer: Verkehr, Baustellen und die allgegenwärtige Elektronik sorgen für immer lautere Geräuschkulissen. Die Akustikforschung steht daher vor der Herausforderung, effektive Lösungen zu entwickeln – und das möglichst ressourcenschonend.

Das klassische Mittel: Dämmmaterialien

Der naheliegendste Ansatz, um Lärm zu reduzieren, ist das Hinzufügen von schallabsorbierenden Materialien. Vliese, Schaumstoffe oder Gummimatten können Schallwellen schlucken, bevor sie als störendes Geräusch wahrgenommen werden. Der Haken: Viele Materialien wirken nur in einem begrenzten Frequenzbereich. Ein Material, das tiefe Brummtöne dämpft, lässt hohe Frequenzen möglicherweise ungehindert passieren.

Ein weiteres Dilemma betrifft den Leichtbau: Wer Lärm durch Masse bekämpft – etwa durch schwere Verkleidungen – erkaufte sich die Stille auf Kosten des Gewichts. Gerade in der Fahrzeugtechnik oder im modernen Bauwesen ist das ein Widerspruch, der nach cleveren Lösungen verlangt. Die Antwort liegt in der gezielten Platzierung optimierter Dämpfungsstrukturen: das richtige Material am richtigen Ort.

Ein Versuchsaufbau zum Anfassen

Um diese Idee experimentell zu erproben, bauten Forschende am Labor für Akustik und Strukturdynamik einen simplen Versuchsaufbau: eine Holzkiste, innen komplett mit Aluminiumblech verkleidet, um harte, schallreflektierende Wände zu simulieren. Ein Lautsprecher sendet Töne in den Innenraum; ein Mikrofon misst die Schalldruckpegel an verschiedenen Positionen.

Das Besondere an der Kiste: Der Boden ist variabel und ermöglicht das Einbringen verschiedener Dämmmaterialien an beliebigen Positionen. Getestet wurden

zunächst vier Materialien – Basotect-Schaum, ein Polyester-Vlies, PE-Schaum und eine Gummi-Granulat-Matte.

Zunächst wurde die leere Kiste ohne Dämmmaterialien vermessen. Dabei wurden die charakteristischen Eigenfrequenzen des Hohlraums ermittelt – jene Frequenzen, bei denen der Schall im Inneren besonders verstärkt wird. Bei Anregung mit diesen Frequenzen wurden dann die Dämmmaterialien systematisch an verschiedenen Positionen auf dem Kastenboden platziert und die Wirkung gemessen.

Simulation trifft Experiment

Parallel zu den Messungen entstand ein digitaler Zwilling der Kiste: ein Finite-Elemente-Modell (FEM), welches die Schallausbreitung im Inneren numerisch berechnet. Die Helmholtz-Gleichung – die mathematische Beschreibung der Druckverteilung eines Schallfeldes im Frequenzbereich – bildet dabei die physikalische Grundlage. Verschiedene Randbedingungen erlauben es, sowohl die schallharten Wände als auch die frequenzabhängigen Dämpfungseigenschaften der Materialien im Modell abzubilden.

Um die Dämpfungswirkung der Materialien im Modell korrekt wiederzugeben, wurden ihre komplexen Impedanzen mit einem Impedanzrohr gemessen – einem Standardverfahren der Akustik, bei dem eine Materialprobe in einem Rohr einer definierten Schallwelle ausgesetzt wird. Die so gewonnenen Materialkennwerte flossen direkt in die Simulation ein.

Der Vergleich zwischen Messung und Simulation zeigte eine gute Übereinstimmung – der digitale Zwilling funktioniert. Damit ist die Grundlage gelegt, um weitere Szenarien rein numerisch zu untersuchen, ohne jedes Mal aufwendige Experimente durchführen zu müssen.

Der genetische Algorithmus: Evolution im Computer

Doch welches Material gehört wohin? Diese Frage systematisch zu beantworten, ist rechnerisch anspruchsvoll – die Zahl möglicher Kombinationen aus Material, Position und Ausdehnung wächst schnell ins Unüberschaubare. Hier kommt ein Optimierungsalgorithmus ins Spiel: ein genetischer Algorithmus, der das Prinzip der biologischen Evolution nachahmt.

Zu Beginn erzeugt der Algorithmus eine zufällige „Population“ möglicher Lösungen – jede mit einem zufälligen Satz an Dämpfungsparametern (Materialeigenschaften, Position). Jede Lösung wird dann in der FEM-Simulation getestet: Wie stark reduziert diese Konfiguration den Schalldruckpegel? Lösungen, die gut abschneiden, werden bevorzugt für die nächste Generation ausgewählt. Durch „Rekombination“ (Mischung der Parameter erfolgreicher Kandidaten) und „Mutation“ (kleine zufällige Änderungen) entsteht eine neue, im Schnitt bessere Population. Dieser Prozess wiederholt sich, bis eine ausreichend gute Lösung gefunden ist.

Ein Vorteil des genetischen Algorithmus gegenüber anderen Methoden: Er kommt auch mit relativ wenigen Trainingsdaten aus – ideal für frühe Entwicklungsphasen, in denen noch keine umfangreiche Datenbasis existiert. Da sowohl das FEM-Modell als auch der Algorithmus vollständig in der Programmiersprache Julia implementiert wurden, ist das Werkzeug frei zugänglich und leicht erweiterbar.

Ausblick: Lärm gezielt bekämpfen

Das vorgestellte Forschungsprojekt zeigt, wie die Kombination aus physikalischem Experiment und numerischer Simulation inklusive Optimierungsalgorithmus neue Wege in der akustischen Optimierung öffnet. Statt flächendeckend Dämmmaterial aufzutragen, lässt sich künftig berechnen, wo ein minimaler Materialeinsatz maximale Wirkung erzielt – ein Gewinn für Leichtbau, Wirtschaftlichkeit und Nutzerkomfort gleichermaßen.

Langfristig kann dieser Ansatz in die Entwicklung von Fahrzeugen, Gebäuden oder industriellen Anlagen einfließen und dazu beitragen, Lärm dort zu bekämpfen, wo er entsteht – intelligent, effizient und mit dem richtigen Material am richtigen Ort.

transform.RMF – Wissenstransfer für die Region Mainfranken

Maschinenbau und Automotive in Mainfranken stehen vor existenziellen Herausforderungen: Die deutsche Autoindustrie befindet sich mitten im tiefgreifenden Strukturwandel, wirtschaftliche Krisen beuteln alle Unternehmen. Die Region mit ihren 55.000 Beschäftigten in den eingangs erwähnten beiden Leitbranchen braucht Transformationsimpulse. Die Transformationsoffensive Regiopolregion Mainfranken (transform.RMF), ein gefördertes Verbundprojekt der Region Mainfranken GmbH und der THWS, unterstützt gezielt kleine und mittlere Unternehmen (KMU). Dank der öffentlichen

Förderung sind die Angebote kostenfrei für Mitglieder und offen für technologieinteressierte Unternehmen.

Von der Ist-Analyse zum Zukunftsbild Mainfrankens

Von Anfang an bedarfsorientiert: Vom Dezember 2022 bis Februar 2023 führten wir eine umfassende IST-Analyse durch. 68 Unternehmen beantworteten unsere quantitative Online-Umfrage, darauf aufbauend entwickelten die vier Transformationscoaches mit einem Dienstleister einen Interviewleitfaden. 38 qualitative Interviews mit Geschäftsführern, CEOs und Managern aus ganz Mainfranken erforschten Herausforderungen, Zukunftsfelder, Schlüsseltechnologien, Kooperationsbedarfe und Erwartungen an transform.RMF.

Ergebnis: Das **Zukunftsbild Mainfranken 2035**. Darin wünschen wir uns Mainfranken als effizientes Innovationsökosystem mit KI, Kreislaufwirtschaft und Klimaneutralität, als Exzellenzcluster für nachhaltige Produktionstechnologien. Die regionalen KMU sind digital miteinander vernetzt, pflegen internationale Partnerschaften und sind attraktiv für Talente weltweit. Prägend ist im Best Case die starke regionale Zusammengehörigkeit, Weltoffenheit und hohe Lebensqualität für alle.

Im letzten Jahr entstand daraus die **Transformations-Roadmap** als konkreter Weg, wie Unternehmen und Region diese Ziele erreichen. Maßnahmenplanung, Veranstaltungsthemen, Learning Nuggets und Demonstratoren wurden präzise darauf abgestimmt.

Transformation zum Anfassen: Live, Kompakt, Vernetzt

Aus Bedarf wird Praxis: Die Erkenntnisse aus IST-Analyse und Zukunftsbild 2035 bestimmen präzise unsere niederschweligen, kostenfreien Angebote. Drei Formate werden kurz vorgestellt:



Gesamtbild mobile Demonstratoren transform.RMF



Das transform.RMF-Team beim ersten Cross Industry Event in Volkach

Auf Marktplätzen, Messen oder Festen präsentieren wir ganztagig mobile Demonstratoren. Jeder kann Technologien ausprobieren, Fragen stellen und über den eigenen Einsatz nachdenken. Wir wollen so Berührungsängste abbauen. Hier eine Übersicht der Use Cases:

Automatisierung & KI:

Zwei Roboter und Förderband simulieren eine Fertigungslinie. Eine KI-Kamera erkennt Objekte und ordnet sie Lagerplätzen zu, per Python-Skript gesteuert.

Additive Fertigung:

Der 3D-Drucker baut Objekte schichtweise aus digitalen Modellen auf. Beim FDM-Verfahren wird Filament geschmolzen, extrudiert und abgekühlt. Effizienz und Nachhaltigkeit werden so greifbar.

Funktechnologie (LoRaWAN):

LoRaWAN ermöglicht IoT-Vernetzung über Kilometer mit 5 Jahren Batterielaufzeit. Der LoRa Alliance-Standard wird von IBM, Cisco, Bosch und der THWS unterstützt.

Augmented Reality:

Die AR-Brille blendet digitale Fabriken in reale Produktionshallen ein. Ein virtueller Rundgang ermöglicht Echtzeit-Anpassungen.

Künstliche Intelligenz:

Beim KI-Game Mensch vs. KI wird ein verpixeltes Bild schrittweise geschärft. Wer es zuerst erkennt, gewinnt.

Maschinendaten – SensoriGo (neu, ausleihbar):

Ein Zwischenstecker misst Stromverbrauch ohne Maschinenumbau. Der Begleitkurs (f-bb/transform.by) erleichtert den Einstieg.

Cross Industry Events: Innovation durch Branchenmix

Unsere Cross Industry Events versammeln unterschiedliche Branchen zu übergeordneten Transformations-Themen. Das Innovationspotenzial liegt im Blick über den Tellerrand: Neue Erkenntnisse, unerwartete Lösungsansätze und Kooperationen entstehen, wenn Maschinenbauer mit Landwirten oder KI-Experten mit Handwerksbetrieben ins Gespräch kommen.

So fand im September 2024 auf der Vogelsburg Volkach die erste Veranstaltung „Maschinenbau und Automotive meets Weinbau und Landwirtschaft“ statt, gefolgt von „KI trifft verschiedene Branchen“ im März 2025 im Kulturspeicher Würzburg. Ein weiteres Cross-Industry-Event ist für Herbst 2026 geplant.

Nach über drei Jahren Netzwerkarbeit wissen wir: Es braucht Offenheit auf allen Seiten. Unternehmen und Gesellschaft müssen technologieoffen bleiben, Wissenschaft muss aus den Büros heraus zu den Menschen gehen. Genau diese gegenseitige Annäherung macht transform.RMF erfolgreich – wir holen ab, begleiten und gestalten gemeinsam die Region.

Mit KI zum optimalen Ergebnis

Ein Beitrag des IDEE zur angewandten KI-Forschung

Wer hat nicht schon einmal Nudeln gekocht. Der erste suchende Blick fällt dabei meist auf die Angabe zur Zubereitungszeit im kochenden Wasser. Hier stellt sich grundsätzlich nicht unbedingt jeder einzelne die Frage, wie genau die Angabe von 10 Minuten ermittelt wurde. In diesem Fall würde es wohl auch nicht sonderlich umständlich sein, in einer Versuchsreihe den Garpunkt manuell im Minutentakt zu testen. Herausfordernder wird die Suche nach dem bestmöglichen Ergebnis jedoch, wenn weitere Suchparameter hinzukommen. Soll beispielsweise der geschmackliche Aspekt mit einfließen, stellt sich zusätzlich die Frage, wie hoch der Salzgehalt des Kochwassers eingestellt werden sollte. Gleichzeitig könnte die ideale Garzeit durch die Änderung des Salzgehaltes beeinflusst werden. Im Vorgehen einer solchen Parametersuche muss nach jedem Versuch entschieden werden, in welcher Form die Änderung beider Parameter zu einem vermeintlich besseren Ergebnis führen. Mehr Salz, weniger Garzeit? Weniger Salz und auch weniger Garzeit? In welcher Größenordnung soll sich die Änderung abspielen?

Die Suche nach optimalen Parametern ist meistens auch Bestandteil der Forschung und Entwicklung. Dabei ist der Klassiker unter den systematischen Herangehensweisen das sogenannte Design of Experiments (DoE) [1]. Hier wird der gesuchte Parameterraum rasterartig abgesteckt und alle so aufgeführten Parametereinstellungen in jeweiligen Experimenten validiert.

Je nach geforderter Präzision kann ein solches Vorgehen jedoch schnell umfangreich werden. Im zweiparametrischen Fall gilt es bei einer Rasterabdeckung von zehn unterschiedlichen Werten pro Parameter bereits 100 Experimente durchzuführen. Bei drei Parametern wären es schon 1.000 Experimente und es wächst mit jedem hinzukommenden Parameter in diesem Fall um den weiteren Faktor von zehn. Ist das beste Resultat aus allen Experimenten erschlossen, so unterliegt sie noch immer einer gewissen Ungenauigkeit. Es ist unwahrscheinlich, dass sich das tatsächliche Optimum genau an einem der Rasterpunkte befindet. Ein noch besseres Ergebnis ist im Zwischenbereich zu einem der anliegenden Rasterpunkte zu erwarten. Für die Suche danach sind wiederum erneute Experimente notwendig.

Eine Alternative wäre die direkte Berechnung des Optimums aus einer gegebenen, mathematischen Funktion. Damit ließen sich die optimalen Parameter direkt per numerischer Optimierung ermitteln und es wären keine zusätzlichen Experimente nötig. Die Konstruktion einer solchen analytischen Funktion kann sich jedoch in beliebiger Komplexität darstellen. Es müssen alle physikalischen und chemischen Einflüsse beachtet werden und wenn nötig an den richtigen Stellen passende Vereinfachungen vorgenommen werden. Letztlich muss auch hier die Richtigkeit der Gleichungen anhand von Experimenten untermauert werden. Es können ungewollt nicht berücksichtigte Einflüsse zwar eine gute Abschätzung für die Validierungsexperimente liefern, jedoch einen so großen Einfluss haben, dass das tatsächliche Optimum nicht mit dem analytischen Optimum übereinstimmt. Fehlende Bausteine müssen hier aufwändig identifiziert, eingearbeitet und wiederum experimentell überprüft werden.




Abbildung 1:
Approximation eines neuronalen Netzes (Gitterdarstellung) an eine unbekannte Funktion durch gegebene Datenpunkte. Die Qualität der Datenpunkte ist ausschlaggebend für eine gute Annäherung.




Abbildung 2:
Auszug aus der Anwendung. In der approximierten Funktion kann die notwendige Änderung der Parameter ermittelt werden, die zu einer potenziellen Verbesserung führt.

Abhilfe schafft die sogenannte surrogatbasierte Optimierung (lat. *surrogatus* „Ersatz“). [2] Grundgedanke hierbei ist, dass ein passender Kandidat als Ersatz für die unbekannte Funktion eingesetzt wird. Dieser soll die Problemstellung bestmöglich mathematisch widerspiegeln und die einfache Auswertung an beliebigen Stellen im unbekannten Parameterraum ohne die Notwendigkeit zusätzlicher physikalischer Experimente ermöglichen. An dieser Stelle kommt die künstliche Intelligenz ins Spiel:

Ein neuronales Netz (NN) [3] besitzt die Eigenschaft des universellen Approximators [4]. Diese besagt, dass es jede beliebig komplexe Funktion bei geeigneter Struktur des Netzes beliebig gut annähern kann. Nach diesem Kenntnisstand ein hervorragender Kandidat für die Nutzung in der surrogatbasierten Optimierung. Ein NN ist dem biologischen Pendant des menschlichen Gehirns nachempfunden. Es besteht aus der strukturierten Verknüpfung von einzelnen Neuronen, die in Schichten angeordnet sind. Bei ausreichender Anregung gibt ein Neuron ein Signal an die damit verbundenen Neuronen einer anliegenden Schicht weiter. Die Intensität der Anregung wird hierbei durch eine angelegte Aktivierungsfunktion ermittelt. Die einzelnen Verbindungen sind zusätzlich unterschiedlich gewichtet, wodurch eine anregende oder dämpfende Wirkung auf das jeweilige verbundene Neuron entsteht.

Das NN wird anhand eines vorliegenden Datensatzes trainiert. Dazu werden besagte Gewichtungen Schritt für Schritt angepasst. Beim Anlegen von Parameterwerten an die Eingangsneuronen der ersten Schicht propagiert eine Welle von Signalen durch das Netz und resultiert in einer Antwort an den Ausgangsneuronen der letzten Schicht. Das Training ist abgeschlossen, wenn zu allen Einträgen im Datensatz die bestmögliche Übereinstimmung mit der Antwort des NN vorliegt. Wenn die bekannten Datenpunkte in ausreichendem Maße gut vorhergesagt werden können, können mit dem trainierten Netz anschließend auch Datenpunkte aus unbekannten Parameterkonstellationen abgefragt werden. Je nach Qualität des Trainingsdatensatzes, -algorithmus und der Netzstruktur können so nutzbare

Abschätzungen ermittelt werden, die die Suche nach dem Optimum ermöglichen (siehe Abb. 1).

Essenziell für die Qualität der Abschätzungen ist die korrekte Generalisierung des NN. Ein NN, das nicht generalisiert, kann die Punkte des Trainingsdatensatzes gut vorhersagen, scheitert jedoch bei der Wertermittlung in unbekannten Parameterbereichen. Es lernt den Datensatz lediglich auswendig, erkennt aber nicht die zugrundeliegende Struktur der unbekannten Funktion. Dadurch entstehen Fluktuationen in unbekannten Bereichen, die die Anwendung der numerischen Optimierungsmethoden erschweren.

Bestandteil der Forschung des IDEE ist die Frage, wie sich für einen gegebenen Problemfall eine solche geeignete Struktur bestmöglich automatisiert ausbildet. Klassische Verfahren etablieren hierfür beispielsweise Regularisierungsterme, die verhindern, dass die einzelnen Gewichte der Verbindungen untereinander in einem schlechten Verhältnis stehen [5]. Die Dropout-Methode [6] schaltet einzelne Neuronen während des Trainings ab und ermöglicht so das Aussortieren von Neuronen mit kontraproduktiver Beteiligung. Jedoch unterliegen solche Generalisierungsverfahren der richtigen Wahl von zugehörigen Einstellparametern, die je nach Datenstruktur unterschiedlich gewählt werden müssen. Zwar haben sich hierfür in der Literatur bereits Werte eingestellt, die überwiegend gute Ergebnisse erzielen, jedoch kann in einzelnen Fällen schlechte Generalisierung resultieren, die wiederum schwierig überprüfbar ist. Untersuchungen haben gezeigt, dass die durchdachte Wahl der Art von Aktivierungsfunktionen eine vertrauenswürdige Generalisierbarkeit im Training von NNs ausbildet, ohne auf die Notwendigkeit zusätzlicher Einstellparameter angewiesen zu sein. Dabei werden in einzelnen Schichten entweder lineare oder nichtlineare Aktivierungsfunktionen in den Neuronen angelegt [7]. Damit können bereits mit wenigen Datenpunkten gute zugrundeliegende Strukturen adaptiert und numerische Optimierungsmethoden angewandt werden (siehe Abb. 2).

Im Vorgehen selbst wird anhand des vorhandenen Datensatzes ein NN trainiert, in dessen Approximation

Input-dimension	1	2	3	4	5	6	7
Schritte bis Optimum Ø	3.9	8.4	13.0	21.6	22.7	37.7	46.5
Treffer aus 10 Durchgängen	10	10	10	10	10	10	10

Tabelle 1: Durchschnittliche Anzahl an Iterationsschleifen in der surrogatbasierten Optimierung mit neuronalen Netzen

an den unbekannten Parameterraum nach einem potenziellen Optimum gesucht wird. Dabei führen speziell entwickelte Methoden und Adaptionen an regulären Optimierungsalgorithmen zu einem Vorschlag, der experimentell validiert wird und dessen Ergebnis als neue Information in den Datensatz einfließt. Damit kann das NN erneut trainiert und die zugrundeliegende Struktur weiter approximiert werden. Die wiederholte Anwendung dieser Optimierungsschleife führt nach und nach zu immer besseren Ergebnissen, die sich sukzessive dem tatsächlichen Optimum annähern. Ein Optimum ist dann gefunden, wenn wiederholt bereits bekannte Vorschläge vorhergesagt werden, also keine neue Information hinzugefügt werden kann.

In Simulationen hat sich hierbei bereits ergeben, dass für eine Problemstellung mit n Suchparametern lediglich ein initialer Datensatz von $n+1$ Datenpunkten für die erfolgreiche Annäherung an ein Optimum ausreichend ist. Die Zahl der notwendigen Iterationen in der Optimierungsschleife kann durch das entwickelte Verfahren signifikant reduziert werden. Im einleitenden Beispiel zur Suche nach der optimalen Zubereitungszeit von Nudeln unter Berücksichtigung des Salzgehalts im Kochwasser wären statt 100 Experimenten im Schnitt nur etwa zehn Kochvorgänge nötig. Die Zahl der Optimierungsschleifen steigt auch hier mit wachsender Parameterzahl, jedoch in so geringem Maße, dass auch mit sieben verschiedenen Parametern nur ungefähr 50 Zusatzexperimente notwendig wären (vgl. Tabelle 1). Im Vergleich zum DoE, das mit hier geforderten 107 = 10 Mio. Experimenten nur noch schwer durchführbar ist. Gleichzeitig wäre das Ergebnis aus dem DoE noch immer auf dem vorgegebenen Raster abgebildet, wohingegen die hier angewandte surrogatbasierte Optimierung zu einem weitestgehend rasterunabhängigen Ergebnis führt. Die Einschränkung beläuft sich lediglich auf die mögliche bzw. nötige Einstellgenauigkeit bei der Durchführung der Experimente. Es macht wohl eher wenig Sinn, den Salzgehalt mit einem einzelnen Salzkorn zu erhöhen.

Eine nicht zu vernachlässigende Herausforderung bildet die mögliche Existenz von mehreren Optima, die sich im Bereich des untersuchten Parameterraums befinden können. Dabei können verschiedene Parameterkonstellationen zu gleichwertigen, besten Ergebnissen führen (globale Optima), aber auch einzelne Parameterpaare ein solches globales Optimum suggerieren, wohingegen andere Parameter ein noch besseres Ergebnis liefern würden (lokales Optimum).

Zugegeben, das ist schon ein recht spezielles Beispiel für die Forschungsarbeiten des Instituts für Digital Engineering. Es beinhaltet jedoch eine Kernbotschaft: jegliche KI-Lösungen bedürfen abgestimmter Methoden, um echte Verbesserungen herbeizuführen. Dieses Kredo führt dazu, dass das IDEE in einer Vielzahl von KI-Projekten nach der „optimalen“ Lösung sucht. Dabei werden nicht nur Standard-KI-Tools eingesetzt, sondern auch eine passende IT-Architektur berücksichtigt sowie die Anforderungen der Praxispartner sehr genau aufgenommen, um einen Mehrwert zu schaffen.

Das IDEE fungiert als Katalysator für die digitale Transformation und positioniert sich als Brückenbauer zwischen KI-Forschung und der industriellen Praxis. Im Kern der Kompetenzen steht die Entwicklung von Digitalisierungslösungen bei gleichzeitiger Befähigung kleiner und mittelständischer Unternehmen, das Potenzial der Künstlichen Intelligenz nicht nur theoretisch zu verstehen, sondern operativ wertschöpfend einzusetzen. Ein zentraler Pfeiler dieser Arbeit ist die Domäne der Generativen KI und Data Intelligence. Hierbei werden KI-Technologien wie Large Language Models oder Retrieval-Augmented Generation (RAG) genutzt, um internes Unternehmenswissen effizient zu erschließen und komplexe Geschäftsprozesse zu automatisieren, ohne dabei die Datensouveränität zu verlieren. Darüber hinaus liegt eine besondere Stärke des IDEE in der tiefen Integration von Software-Intelligenz in die physikalische Produktion. Letztlich zeichnet sich das IDEE durch einen interdisziplinären Engineering-Ansatz aus, der den gesamten Lebenszyklus eines

IT- und KI-Systeme von der Datenakquise über die Modellierung bis hin zur Implementierung im Praxisumfeld abdeckt und so die Innovationskraft des Standorts Mainfranken nachhaltig stärkt.

DIG:IT KMU, Datenintelligenz in der IT

Wissen steckt in den Daten

Viele KMUs aus der Automobil- und Maschinenbaubranche verfügen über umfangreiches dokumentiertes Wissen – doch es schlummert oft ungenutzt in Excel-Tabellen und PDF-Dateien. Einfach abrufbar ist es selten. Dabei wächst der Druck: Zulieferer müssen effizienter arbeiten, schneller entscheiden und ihre Wertschöpfungsketten resilienter machen. KI-Technologien bieten dafür enorme Potenziale – sind für viele Betriebe aber schwer zugänglich.

KI-Technologien maßgeschneidert für KMUs

Das EFRE-geförderte Projekt DIG:IT KMU der THWS schließt diese Lücke. Mithilfe von Large Language Models (LLMs) und Retrieval-Augmented Generation (RAG) wird das dokumentierte Wissen der Unternehmen intelligent nutzbar gemacht. Das Framework K-RagRec nutzt dabei Wissensgraphen, um strukturierte und aktuelle Informationen präzise zu extrahieren und KI-typische Fehlinformationen zu vermeiden. Graph Convolutional Networks (GCNs) sorgen für schnelle Datenabrufe, eine Multi-Head Early Exit-Architektur reduziert den Rechenaufwand – ohne Abstriche bei der Genauigkeit.

Das Projekt verfolgt ein klares Ziel: KMUs sollen ihre Daten eigenständig, effizient und sicher nutzen können. Die entwickelten Technologien sind so konzipiert, dass sie branchenunabhängig und unternehmensübergreifend einsetzbar sind. Damit stärkt DIG:IT KMU nicht nur die Wettbewerbsfähigkeit der teilnehmenden Betriebe, sondern auch ihre digitale Souveränität – und trägt zur Reduzierung strategischer Abhängigkeiten von außereuropäischen Technologieanbietern bei.

Digitale Souveränität stärken

Das Projekt verfolgt ein klares Ziel: KMUs sollen ihre Daten eigenständig, effizient und sicher nutzen können. Die entwickelten Technologien sind so konzipiert, dass sie branchenunabhängig und unternehmensübergreifend einsetzbar sind. Damit stärkt DIG:IT KMU nicht nur die Wettbewerbsfähigkeit der teilnehmenden Betriebe, sondern auch ihre digitale Souveränität – und trägt zur Reduzierung strategischer Abhängigkeiten von außereuropäischen Technologieanbietern bei.

Von der Idee bis zum Go-Live

13 KMUs aus der Region Mainfranken bringen ihre konkreten Anwendungsfälle ein – von der Gefahrstoffverwaltung über die Bauteilkonfiguration bis zum Anlagenbau. In einem bewährten phasenbasierten Ansatz begleitet das IDEE-Institut der THWS die Unternehmen vom Kreativ-Workshop bis zur produktiven Inbetriebnahme. Technologietransfer wird damit nicht zur abstrakten Fördermaßnahme, sondern zu handfestem Mehrwert im Betriebsalltag.

**Short
Facts:**

Thema

Digital Engineering

Leitung

**Prof. Dr.-Ing. Andreas Schiffler
Prof. Dr.-Ing. Bastian Engelmann**

Standort & Kontakt

**Ignaz-Schön-Straße 11
97421 Schweinfurt
idee@thws.de**

Forschungsfelder

**Intelligent Production System
Additive Metal Printing
Computational Science
Mechanical Systems**