



DIGITAL INDUSTRIES SOFTWARE

KI-Nutzung im Prozess der Fahrzeugkonstruktion

Maschinelles Lernen als Ergänzung zum menschlichen Verstand bei der Verbesserung der Produktentwicklung

Kurzdarstellung

Künstliche Intelligenz (KI) ist kein Regressionsmodell aus vorhergesagten Werten und gemessenen Ergebnissen. Sie enthält jedoch Aspekte davon. Wenn die Technologie verstanden und ihr volles Potenzial ausgeschöpft werden kann, dürfte sie die menschlichen Fähigkeiten vervielfachen und die Entwicklung und Entdeckung neuer Technologien beschleunigen. Um diese Idee zu untermauern, wird in diesem White Paper ein Framework für die Anwendung von KI auf den Fahrzeugentwicklungsprozess vorgestellt.

Unser 3D-Framework („dull, data rich, decision support“; monoton, datenreich und entscheidungsorientiert) kombiniert die Stärken des menschlichen Geistes mit denen einer Maschine, um die immer komplexer werdende Welt der heutigen Technik vorteilhaft nutzen zu können. Wir zeigen Ihnen anhand konkreter Beispiele, wo KI zum Einsatz kommt und wie sie implementiert werden kann.

Inhalt

Einführung	3
1. KI ist die Mühe wert	4
Schlüsselkator 1: Big Data	4
Schlüsselkator 2: Hardwarekapazität und Rechenleistung	4
2. Eine kurze Einführung in die KI-Terminologie	5
Überwachtes Lernen	5
Unüberwachtes Lernen	5
3. 3D-Framework: monoton, datenreich und entscheidungsorientiert	6
Monotone Aktivitäten	6
Datenreiche Umgebungen	7
Entscheidungsorientierte Anwendungen	9
Fazit	11
Referenzen	11

| Einführung

Der Sieg des IBM-Supercomputers *Deep Blue* über den damaligen Schachweltmeister Gary Kasparow im Jahr 1997 brachte die Leistungsfähigkeit und Reife der KI ins Bewusstsein der breiten Öffentlichkeit. Dies war der Höhepunkt einer einhundert Jahre währenden Arbeit an KI, einschließlich Alan Turing – beispielsweise das bahnbrechende Dokument „Computing Machinery and Intelligence“ aus dem Jahr 1950, das einen Test für intelligente Maschinen vorschlug.

Seit dem Sieg von *Deep Blue* ist der Einsatz von KI allgegenwärtig, aber unauffällig geworden. Der United States Postal Service nutzt KI, um handgeschriebene Postleitzahlen zu erkennen und Briefe zu sortieren. Suchmaschinen verwenden sie, um relevante Daten für Anwender zu finden.

Die Anwendung von KI in der Automobilindustrie war bisher jedoch nur sporadisch. Es kommt darauf an, dass die einzelnen Teams mit den Tools und Konzepten der KI vertraut sind.

Wir stellen ein praktisches Framework zur Verfügung, um über Probleme nachzudenken, die mit KI gelöst werden sollten. So können wir die Fähigkeiten der KI nutzen, um die Entwicklung neuer Technologien zu beschleunigen.



Abbildung 1: Ein Computer schlug 1997 den amtierenden Schachweltmeister Gary Kasparov.

1. KI ist die Mühe wert

Sie fragen sich vielleicht: „Warum sollte man sich überhaupt mit KI beschäftigen? Das derzeitige Verfahren hat bei der Entwicklung von Weltklasseautos mehrere Jahrzehnte lang gut funktioniert und Sie haben bereits einige brillante Konstrukteure. Die Computer können sie unmöglich ersetzen.“

Das stimmt.

Wir glauben jedoch, dass KI bei späteren Konstruktionen einen Vorsprung verschaffen kann, indem sie historische Daten nutzt.

Wir sind der Ansicht, dass KI Fehler erkennen kann, die wahrscheinlich unbemerkt bleiben würden, bis es zu spät ist.

Nach unserer Überzeugung kann KI Ihnen Lösungswege viel schnellere aufzeigen: sei es bei der Analyse, bei der Verarbeitung von Daten oder bei der Erarbeitung einer soliden Antwort.

Jetzt ist der perfekte Zeitpunkt, um die Vorteile der künstlichen Intelligenz zu nutzen, da es in diesem Bereich zwei wichtige Voraussetzungen gibt.

Schlüsselfaktor 1: Big Data

Big Data – extrem große und komplexe Datenbestände – hat sich weltweit durchgesetzt. Wir generieren wöchentlich Terabytes an Daten aus computergestützten Konstruktionslösungen (CAE), die Gleichungen und in Testzellen erfasste Daten verarbeiten.

Neunzig Prozent dieser Daten werden vor allem deshalb verworfen, weil wir nicht die Zeit haben, nicht unmittelbar benötigte Daten zu verarbeiten, auch wenn sie wertvolle Erkenntnisse für die Zukunft enthalten könnten.

KI ist exponentiell besser in der Lage, große Datenmengen zu verarbeiten und effizient Muster zu erkennen und zu extrahieren, an die unser analoges Gehirn niemals denken würde, egal wie viel Zeit wir mit der Durchsicht der Daten verbringen. Überlassen wir also der KI die Bewältigung großer Datenmengen, die Mustererkennung und die Entwicklung einzigartiger Verbindungen, die unser analoges Gehirn aufgreifen, verstehen und lösen kann.

Schlüsselfaktor 2: Hardwarekapazität und Rechenleistung

Sie brauchen kein Informatikstudium mehr, um KI zu betreiben, da zunehmend preiswerte Hardware-Rechenkapazitäten und Software-Tools zur Verfügung stehen.

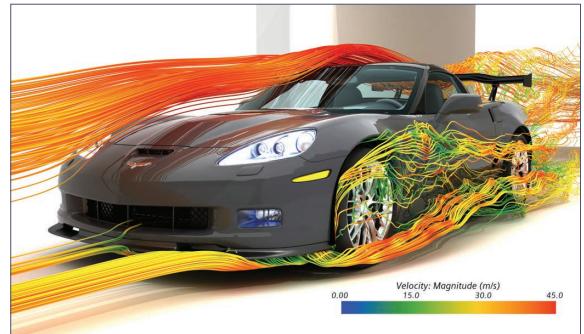


Abbildung 2: Der Einsatz von Simcenter STAR-CCM+ ermöglicht schnellere Durchlaufzeiten bei geringeren Hardware-Investitionskosten.

Die Verbreitung von Hochleistungsrechnern und Grafikprozessoren (GPUs) in der Spiele- und Konsumgüterindustrie hat zu einem Preisverfall geführt. Jüngste Leistungsvergleiche von externen Aerodynamikberechnungen in Industriequalität (siehe Abbildung 2 für ein Berechnungsbeispiel) auf GPUs haben eine 160-fache Erhöhung der Geschwindigkeit und eine 90-prozentige Verringerung des Stromverbrauchs ergeben (siehe Abbildung 3 für den Leistungsvergleich von GPUs).

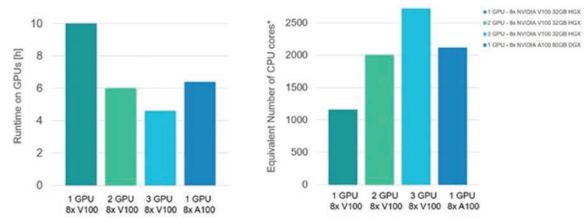


Abbildung 3: GPU-Leistungsvergleich

2. Eine kurze Einführung in die KI-Terminologie

In unserer Erörterung werden wir Methoden für maschinelles Lernen (ML) verwenden – eine Teilmenge der KI.

Überwachtes Lernen

Überwachtes Lernen ist eine Methode, bei der dem KI-Algorithmus die richtige Antwort vorgegeben wird. Dem Algorithmus wird mitgeteilt, was die Eingaben sind und was die richtige Antwort sein soll, wie in Abbildung 4 dargestellt. Dann wird der Algorithmus anhand eines Datenbestands mit Inputs und Outputs geschult, bevor dieser selbstständig Vorhersagen auf der Grundlage nie zuvor gesehener Input-Kanäle macht.

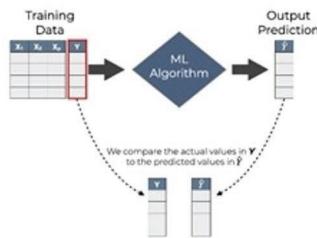


Abbildung 4: Beim überwachten Lernen überwacht die Zielvariable Y den Modellierungsprozess.

Ein Beispiel für überwachtes Lernen ist ein Fahrzeug, das Stoppschilder erkennt. Die Rohdaten der Kameras werden als Inputs gekennzeichnet und die endgültige richtige Antwort (ein Stoppschild) wird als Output markiert.

Daher spricht man beim überwachten Lernen von gelabelten Daten.

Unüberwachtes Lernen

Unüberwachtes Lernen ist eine Methode, bei dem Algorithmus keine endgültige Antwort vorgegeben wird. Stattdessen bitten wir den Algorithmus, die Daten zu verarbeiten und interessante Trends und Muster zu finden. Da die Daten nicht gelabelt sind, sind die menschlichen Eingriffe deutlich geringer.

Laut IBM Cloud Education¹ gibt es drei ideale Anwendungen für unüberwachtes Lernen: Clustering, Assoziation und Dimensionalitätsreduktion.

Clustering-Algorithmen ermitteln die Hervorhebung von Mustern und Gemeinsamkeiten in einem Datenbestand, die für den menschlichen Verstand nicht erkennbar sind

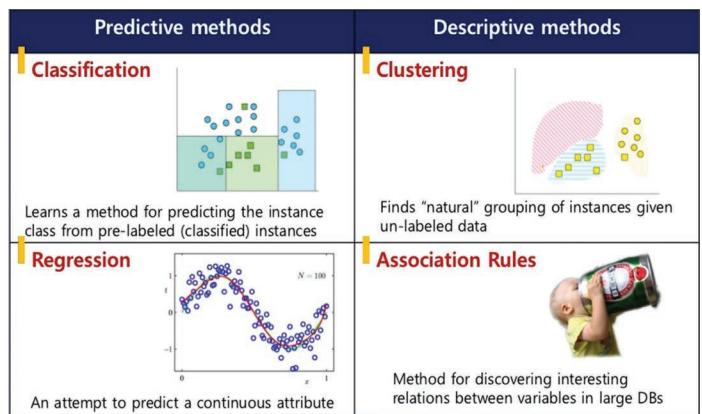


Abbildung 5: Gängige Methoden des unüberwachten Lernens

oder sich mit klassischen statistischen Methoden nicht ermitteln lassen.

Assoziationsalgorithmen verwenden die Daten von zwei Variablen, um eine Relation zu finden. Das Netflix-Empfehlungssystem gibt Kunden Empfehlungen aufgrund von Titeln, die sie sich bereits angesehen haben. Das ist ein Beispiel für eine Assoziationsanalyse.

Die Dimensionalitätsreduktion reduziert einen großen Datenbestand auf eine handhabbare Größe, ohne die in den Daten enthaltenen Trends und Nuancen zu beeinträchtigen. Dies wird dadurch erreicht, dass die Anzahl der Zufallsvariablen im jeweiligen Fall reduziert wird, während die meisten sinnvollen Eigenschaften der ursprünglichen Daten erhalten bleiben.

Das frühere Beispiel des Schachspiels veranschaulicht die Leistungsfähigkeit des unüberwachten Lernens. Die Züge, die Kasparov in jenem bahnbrechenden Match vor zwei Jahrzehnten besiegt, gelten nach heutigen Maßstäben als einfach, mittelmäßig. Das Schachspiel hat seit dem Aufkommen von KI einen langen Weg zurückgelegt, indem es Züge und Muster identifiziert hat, an die erfahrene Großmeister nicht gedacht hatten. Die Schachgroßmeister von heute stützen sich auf Millionen von Schachpartien, die KI-Computer spielen, um neue Züge zu entdecken.

Das schaffen wir auch – mit unserem Produktentwicklungsprozess und den Terabytes an Daten, die wir erzeugen.

Wir können neue, aber kontraintuitive Handlungswege identifizieren.

3. 3D-Framework: monoton, datenreich und entscheidungsorientiert

Wir schlagen das folgende Framework für die Anwendung von maschinellem Lernen vor:

Monoton, datenreich und entscheidungsorientiert sind spezifische Szenarien, in denen die Maschine dem menschlichen Verstand bei der jeweiligen Aufgabe überlegen ist und den menschlichen Verstand ergänzen kann, um eine weitaus größere Leistung zu erzielen.

Monotone Aktivitäten

Sich wiederholende und langwierige Arbeit ist eine bedauerliche Realität im heutigen Konstruktionsprozess. Diese sich wiederholenden Tätigkeiten sind monoton, erfordern wenig Engagement des Konstrukteurs und nehmen viel Zeit für die Ausführung in Anspruch. Beispiele hierfür sind die Überprüfung eines großen Datenbestands auf Kohärenz vor der Verwendung oder die Vorbereitung der Geometrie einer computergestützten Konstruktion (CAD) für die Analyse. Ein manuelles Verfahren verzögert den Konstruktionsprozess und verursacht hohe Kosten, da teure Arbeitskräfte für ungelernte Aufgaben verschwendet werden. Außerdem schleichen sich aufgrund der sich wiederholenden Arbeiten Fehler ein.

Hier ist ein Beispiel, bei dem wir überwachtes Lernen eingesetzt haben, um die vier Tage dauernde CAD-Geometriebereinigung zu automatisieren und auf einen halben Tag zu reduzieren.

Verwendung der CAD-Geometriebereinigung für CAE-Analysen

Die vom Konstrukteur erstellte CAD-Rohgeometrie ist selten sofort bereit, vernetzt und analysiert zu werden. Es gibt Lücken, wo sich die Flächen treffen, hohle

2D-Flächen anstelle von 3D-Volumenkörpern und das Vorhandensein vieler kleiner Teile, wie Schrauben und Befestigungselemente, die für eine bessere Netzgenerierung entfernt werden müssen.

Wir haben ML eingesetzt, um Schrauben und Muttern automatisch zu identifizieren. Geometriedaten aus früheren Fahrzeugprogrammen wurden verwendet, um den ML-Algorithmus auf denselben Bauteilen zu trainieren, die bei der Geometriebereinigung identifiziert, markiert und entfernt werden mussten.

Sobald der ML-Algorithmus trainiert ist, kann er dazu verwendet werden, CAD-Geometrien von Fahrzeugen zu verarbeiten, die er noch nie zuvor gesehen hat, und die zu löschen den Bauteile automatisch zu identifizieren. Abbildung 6 zeigt das Ergebnis des ML-Algorithmus, der die zu löschen den Schrauben und Muttern identifiziert und markiert hat.

In diesem Fall hat der Konstrukteur die Tags dennoch überprüft und sichergestellt, dass die Identifizierung korrekt und vollständig war. Dieser „Expert-in-the-Loop“-Prozess sorgt für eine hochwertige Arbeitsqualität und automatisiert gleichzeitig den langwierigen, mühsamen Prozess der CAD-Geometriebereinigung.

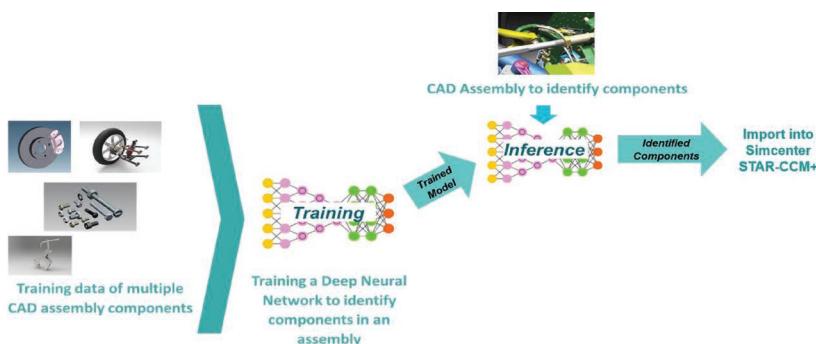


Abbildung 6: Workflow der CAD-Teileerkennung zur Identifizierung von Bauteilen. Beachten Sie, dass im vorliegenden Beispiel der Datenbestand von zwei Fahrzeugen stammt.



Abbildung 7: Der ML-Algorithmus identifiziert und markiert automatisch die zu entfernen den Schrauben und Muttern, auch wenn diese Geometrie noch gänzlich unbekannt ist.

Ein ähnliches überwachtes Lernen kann auch die fehlenden Materialeigenschaften im CAD identifizieren und ergänzen.

Datenreiche Umgebungen

Datenreich mag ein Kriterium sein, das seltsam klingt.

Datenreichtum ist keine Anwendung, sondern eine notwendige Voraussetzung für ML. Die Anwendung von ML in datenreichen Umgebungen ist vergleichbar mit der Suche nach Leben, wo es Wasser gibt. Dabei gehen wir nicht von einem zu lösenden Problem aus, sondern kehren den Gedanken um und fragen: „Was kann ich mit all diesen Daten tun oder lernen?“

Durch eine derartige Umstellung der Denkweise ergeben sich zahlreiche Anwendungsmöglichkeiten.

Wir können überwachte und unüberwachte Lernmethoden nutzen, um Erkenntnisse aus diesen großen Datenbeständen zu gewinnen, die aus CAE und Tests stammen.

Nutzung großer Mengen von CAE-Daten: Modelle reduzierter Ordnung

Ein Modell reduzierter Ordnung (reduced order model, ROM) ist eine Vereinfachung eines statischen oder dynamischen Modells mit hoher Genauigkeit, bei dem das wesentliche Verhalten und die dominanten Effekte beibehalten werden, um die Lösungszeit oder die Speicherkapazität zu verringern, die für das komplexere Berechnungsmodell (z. B. ein 3D-Finite-Elemente-Modell) erforderlich ist. Im Vergleich zu datenreichen Umgebungen reduzieren ROMs die Anzahl der Variablen in den Systemen, wobei die Genauigkeit des ursprünglichen komplexen Berechnungsmodells erhalten bleibt. ROMs sind daher viel schneller und unkomplizierter. Ein beliebter Lösungsansatz für die Erstellung eines ROM ist die Verwendung von ML, das

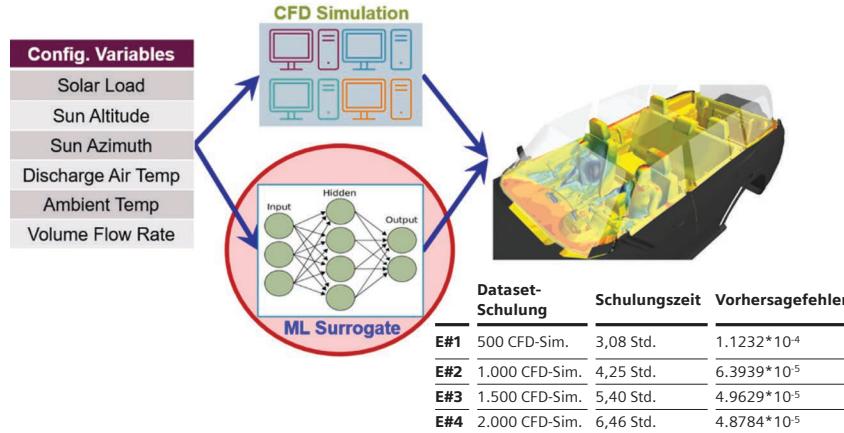


Abbildung 8: Konfigurationsvariablen und Fehler bei der Vorhersage von Modellen reduzierter Ordnung für verschiedene Größen von Schulungsdatenbeständen

auf den Ergebnissen einer detailgetreuen CAE-Analyse verwendet wird.

In dem hier diskutierten Fall wurde ROM zur Vorhersage der Oberflächentemperaturverteilung in einer Fahrzeugkabine verwendet. Eine Datenbank mit Simulationsergebnissen wurde erstellt, indem mehrere detailgetreue numerische Strömungsmechanik-Simulationen (computational fluid dynamics, CFD) in einem Batch-Lauf für verschiedene Betriebsbedingungen und Inputs durchgeführt wurden.

Das Team testete die Genauigkeit des ROM, das anhand von 500, 1.000, 1.500 und 2.000 Datenproben trainiert wurde. Das ROM-Modell hat sogar den kleinsten Datenbestand richtig vorhergesagt, wie in Abbildung 8 zu sehen ist.

Das ML-Modell benötigt nur wenige Sekunden für die Vorhersage der Temperaturen, während eine detailgetreue CFD mehrere Stunden benötigt. Dieses ROM kann für Vorhersagen verwendet werden, wenn sich die Kabinengeometrie nicht wesentlich ändert. In der folgenden Abbildung werden die verschiedenen ML-Modelle mit Messdaten verglichen.

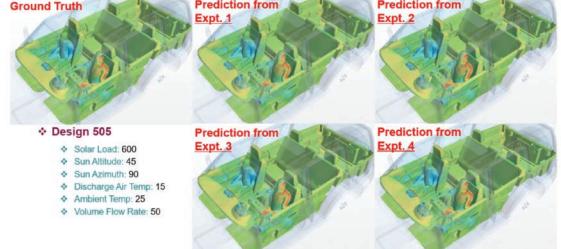


Abbildung 9: Vergleich der Innenraumtemperaturverteilung anhand jedes der trainierten ROM-Modelle

Sobald ein ROM generiert wurde, kann es in ein Systemmodell (z. B. ein 1D-Klimaanlagen- und Wärmepumpenmodell) integriert werden, um genaue 3D-Vorhersagen eines CFD-Modells mit der Geschwindigkeit eines 1D-Modells zu replizieren. Eine komplette Fahrzyklusanalyse, eine Multi-Attribut-Balancierung oder die Entwicklung von Steuerungen kann nun in einem Bruchteil der Zeit durchgeführt werden.

Nutzung von Testdaten Teil I: Modelle für nichtlineare Teilsysteme

Betrachten wir ein Szenario, bei dem Testdaten die Quelle sind.

Wenn ML auf Testdaten angewendet wird, kann es zur Lösung schwieriger Probleme bei der Simulationsmodellierung verwendet werden, z. B. bei Bauteilen mit komplexen nichtlinearen Eigenschaften.

Die Arbeit von Nakatsugawa² befasst sich mit einem selbst schaltbaren Hydro-Mount-Bauteil, das eine nichtlineare Charakteristik in Abhängigkeit von Amplitude und Frequenz aufweist. Das Hydrolager wurde durch verschiedene Frequenzsweeps mit konstanter Amplitude angeregt, wobei die Eingangsverschiebung und die hydraulische Ausgangskraft gemessen wurden. Dann wurde ein ML-Modell trainiert, um die Zeitreihe der hydraulischen Kraft anhand der Input-Verschiebung vorherzusagen.

Das ML-Modell zeigte eine Genauigkeit von über 90 %, was mit einem physikalischen Modell vergleichbar oder sogar besser ist. Außerdem war das datengesteuerte Hydro-Mount-Modell zeitstabil und konnte direkt in ein größeres instationäres 1D-CAE-Systemmodell integriert werden.

Ein ähnlicher Lösungsansatz wie der von Gorgoretti³ wurde verwendet, um ein Reifenmodell zu generieren, das sich in ein Simulationsmodell der Fahrzeugdynamik mit 15 Freiheitsgraden (degrees-of-freedom, DOF) integrieren lässt. Die erhaltenen Reifenmodelle waren vergleichbar (zwischen 9 und 17 % mittlerer absoluter Fehler) mit realitätsgetreuen, physikalischen Reifenmodellen, die mit schwerfälligeren konventionellen Mitteln generiert werden, z. B. wenn eine spezielle Testinfrastruktur (ein spezieller Reifenteststand) und ein spezifisches Testverfahren erforderlich sind.

Dieser Lösungsansatz spart nicht nur Zeit bei der Modellierung, sondern macht auch diese zusätzlichen speziellen Tests überflüssig.

Nutzung von Testdaten Teil II: Datengesteuerte virtuelle Sensoren

Bei der Erprobung von Fahrzeugen auf Teststrecken wird das Fahrzeug traditionell mit vielen verschiedenen Sensoren ausgestattet, um das dynamische Verhalten

einer neuen Fahrzeugvariante zu charakterisieren. Zu den bei diesen Tests verwendeten physikalischen Instrumenten gehören einige teure und schwer zu installierende Sensoren.

Wir haben Messdaten von billigeren und einfacher zu installierenden Sensoren verwendet, um die erwartete Leistung von teuren und umständlich zu installierenden physikalischen Sensorsignalen abzuschätzen. Dies wird erreicht, indem der ML-Algorithmus anhand früherer Messdaten geschult wird, wobei die Vorhersageziele die schwierigen Sensoren (z. B. Radkraft-Messwandler) und die Inputs für das Modell die billigeren Sensoren (z. B. Beschleunigungsmesser und Dehnungsmessstreifen) sind.

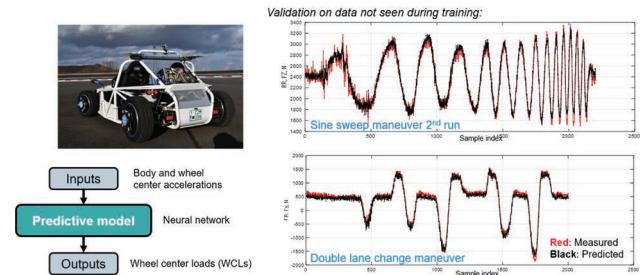


Abbildung 10: Demonstration der Genauigkeit eines ähnlichen Lösungsansatzes, der auf das Siemens-Demonstrationsfahrzeug „Simrod“ angewendet wurde, um die Belastung der Radmitte vorherzusagen

Automatisiertes Benchmarking mit unüberwachtem Clustering von historischen Daten

Viele Automobil-Erstausrüster (OEMs) verfügen über große historische Datenbanken mit Testmessungen. Obwohl diese Datenbanken potenziell nützliches Wissen enthalten, analysieren die Konstrukteure in der Praxis aus Zeitmangel höchstens bis zu 30 % der gesamten Messdaten, wodurch ihnen wahrscheinlich einige wesentliche Erkenntnisse entgehen.

Außerdem sind diese Expertenanalysen oft reaktiv (z. B. reagieren sie, nachdem ein Problem aufgetreten ist).

Unüberwachte Clustering-Ansätze sind nützlich, weil sie automatisch die relevantesten Cluster in der Datenbank identifizieren, die dann für eine gründlichere Analyse an die Experten weitergegeben werden können.

Beim NVH-Benchmarking (noise, vibration and harshness) wurde ein hierarchischer Lösungsansatz verwendet, um das Leistungsvermögen einer Fahrzeugflotte in Bezug auf die Geräuschqualität auf der Straße zu vergleichen. Die Fahrzeuge wurden auf einem Automobil-Testgelände bei Testfahrten im Leerlauf gefahren, und im Innenraum jedes Fahrzeugs wurden akustische Aufnahmen gemacht.

Das Ziel des Benchmarkings war es, die relative Leistung in Bezug auf die Geräuschqualität der Fahrzeuge zu verstehen.

Die manuelle Auswertung der Daten erwies sich als schwierig und zeitaufwendig. Es war möglich, wenn man nur eine Kennzahl betrachtete, aber nahezu unmöglich, wenn man 10 Kennzahlen gleichzeitig betrachtete, selbst mit herkömmlichen statistischen Methoden.

Es lag auf der Hand, eine unüberwachte Clustering-Methode für dieses Problem zu verwenden.

Durch die Anwendung eines agglomerativen hierarchischen Clustering-Ansatzes auf die extrahierten Metriken für die Geräuschqualität jedes Fahrzeugs und die anschließende Visualisierung des Dendrogramms kann der Konstrukteur einen globalen Überblick über die Trends in den akustischen Daten erhalten.

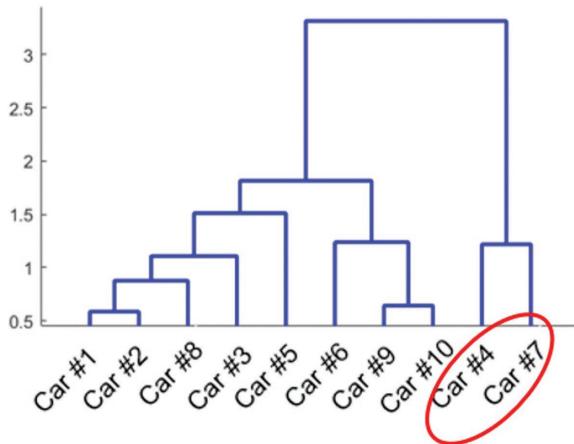


Abbildung 11: Ein Dendrogramm, das die Ergebnisse des hierarchischen Clustering für Geräusche zeigt, die in einer Flotte von 10 Fahrzeugen aufgenommen wurden

Sie sehen, dass die Fahrzeuge Nr. 4 und Nr. 7 bei verschiedenen Messungen durchweg in einem Cluster liegen, was darauf hindeutet, dass sie eine vergleichbare Leistung in Bezug auf die Geräuschqualität haben. Verschiedene Fahrzeugsegmente weisen jedoch auf ein mögliches Problem bei einem der beiden Fahrzeuge hin.

Der Konstrukteur der Forschungs- und Entwicklungsabteilung (F&E) kann dann eine detailliertere Analyse der einzelnen Geräuschqualitätsmetriken durchführen (siehe Abbildung 11), um zu verstehen, warum sich diese Fahrzeuge vom Rest der Flotte unterscheiden und welcher Aspekt der Klangqualität die Hauptursache für diesen Unterschied war.

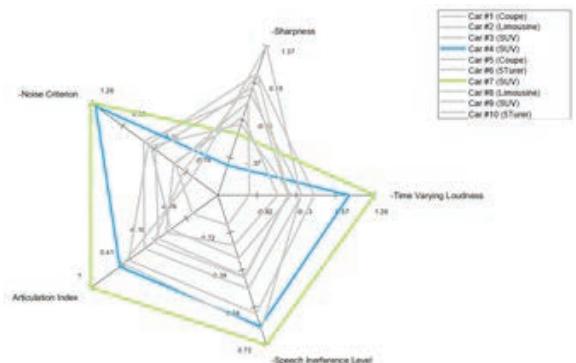


Abbildung 12: Radar-Diagramm mit weiterer Aufschlüsselung der Geräuschqualitätsmetriken, wobei die Trends der Fahrzeuge Nr. 4 und Nr. 7 hervorgehoben sind

Entscheidungsorientierte Anwendungen

Die Verwendung von KI in entscheidungsorientierten und diagnostischen Anwendungen ist aus zwei Gründen eine gute Wahl.

Erstens ist das menschliche Urteilsvermögen verzerrt. Daniel Kahneman hebt dies in seinem Buch *Noise* hervor: *Eine Schwäche des menschlichen Urteilsvermögens*,⁵ besteht darin, dass Menschen nicht nur unterschiedliche Urteile über dieselben Daten fällen, sondern dass ein und dieselbe Person auch morgens und nachmittags unterschiedliche Urteile über ein und denselben Fall treffen kann. Eine Versuchsperson, die den Komfort in einer identischen Umgebung beurteilt, könnte beispielsweise den Komfort auf der Grundlage vieler Faktoren beurteilen, die nichts mit dem Komfort des Fahrzeuginnenraums zu tun haben (z. B. Schlaf, Gesundheit und ob der lokale Sportverein am Vorabend gewonnen oder verloren hat).⁵ Eine Verringerung dieser Variabilität wird zu einer robusteren Technik führen.

Zweitens sind Menschen nicht gut darin, Anomalien bei vielen Variablen zu erkennen oder wenn sich die Trends über einen langen Zeitraum entwickeln – zum Beispiel eine langsame Verschlechterung des Leistungsvermögens eines Teils, das mehrere Tage lang im Einsatz ist. Eine manuelle Überprüfung der Telemetriedaten könnte das Problem erst bei einem Ausfall erkennen, während dies mit einem KI-Algorithmus viel früher möglich ist.

Sehen wir uns zwei Beispiele an, bei denen KI in entscheidungsorientierten Anwendungen erheblich helfen kann.

Ermittlung fehlerhafter Teile

Die Arbeit von Hendrickx⁶ bietet ein gutes Beispiel für die Anwendung des maschinellen Lernens bei der Erkennung von Anomalien. Mehrere elektrische Maschinen einer Flotte werden in einem gemeinsamen Lagerraum getestet. Elektrische und Schwingungssignaturen werden an verschiedenen Stellen gemessen und zur Schulung von maschinellen Lernmodellen verwendet, um unsicheres Betriebsverhalten eines bestimmten Bauteils zu erkennen.

Mit einem ähnlichen Lösungsansatz können ML-Modelle die langsame Degradierung von Batterien oder kritischen Bauteilen in Fahrzeugen im Betrieb erkennen, indem sie Telemetriedaten analysieren.

Verringerung von subjektiven Beurteilungen

ML-Modelle können eine geeignete Alternative zu vielen subjektiven Beurteilungen in Bezug auf das Leistungsvermögen einer Konstruktion darstellen.

Die Arbeit von Lopes⁷ zeigte, wie trainierte neuronale Netze die Reaktion von Mitfahrern auf



Abbildung 13: Erkennen von fehlerhaften Bauteilen mithilfe von ML

Innenraumgeräusche vorhersagen. Das Ziel des neuronalen Netzmodells war es, eine Beziehung zwischen objektiven und subjektiven psychoakustischen Eigenschaften herzustellen. Dank dieser Fähigkeit lassen sich komplexe Modelle in Bezug auf menschlichen Komfort und Präferenzen in das Framework für virtuelle Prototypenerstellung integrieren.

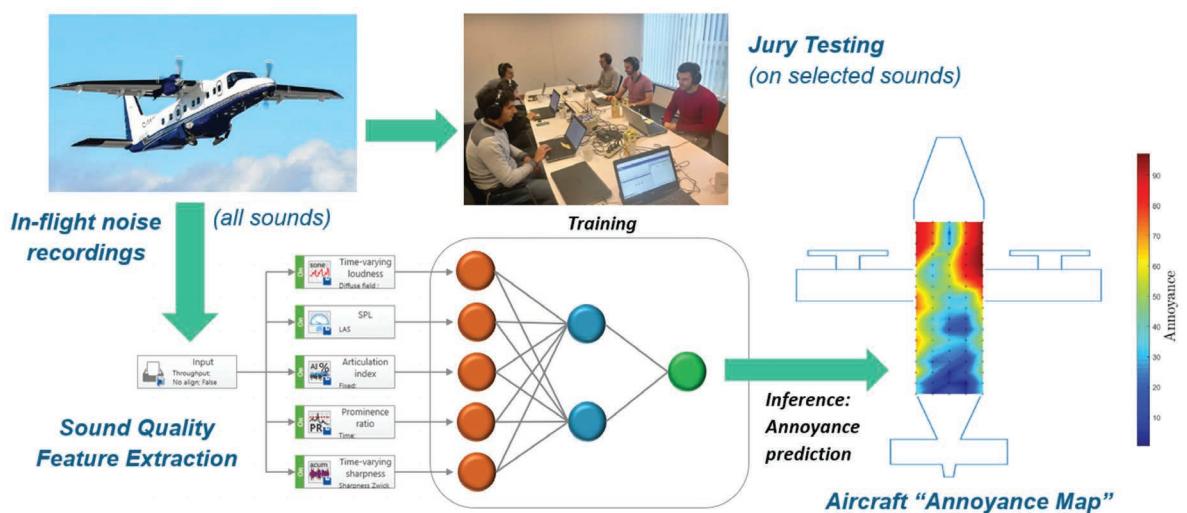


Abbildung 14: Verfahren zur Entwicklung einer Daten- und Analysepipeline für die Schulung eines neuronalen Netzwerks in Bezug auf Störgeräusche

Fazit

Angesichts des rasanten Fortschritts bei der Datengenerierung und der Verfügbarkeit von Tools für künstliche Intelligenz ist es an der Zeit, KI auf den Entwicklungsprozess von Fahrzeugen anzuwenden.

Unser Framework für die Anwendung des maschinellen Lernens (monoton, datenreich und entscheidungsorientiert) zeigt spezifische Szenarien auf, in denen die Maschine den menschlichen Verstand ergänzen kann, um eine im Vergleich zum jetzigen Stand höhere Geschwindigkeit und Effizienz zu erreichen.

Die Anwendung von ML auf langwierige Prozesse wie die CAD-Vorbereitung für externe aerodynamische Analysen zeigt eine 8-fache Beschleunigung – damit lässt sich der Zeitaufwand von vier Tagen auf einen halben Tag reduzieren.

Die Generierung von Modellen reduzierter Ordnung bringt die hohe Genauigkeit einer 3D-CAE-Analyse in ein schnell laufendes 1D-Systemmodell und ermöglicht so die Abwägung mehrerer Attribute, robustes Engineering und die Entwicklung komplexer Steuerungen.

Bei der Anwendung auf Testdaten kann ML in einem Bruchteil der Zeit genaue Subsystemmodelle komplexer nichtlinearer Systeme erstellen – ohne Modellierung der Physik und ohne Feinabstimmung des Modells.

Und schließlich bringt unüberwachtes Lernen Erkenntnisse, die zuvor übersehen wurden. Dadurch wird die Zahl der nachfolgenden Konstruktionsänderungen und der Fehler im realen Betrieb reduziert.

Referenzen

1. <https://www.ibm.com/cloud/learn/unsupervised-learning>
2. Nakatsugawa, Eiji, et al. „Development of modeling method for the self switchable hydromount by machine learning.“ *Transactions of Society of Automotive Engineers of Japan* 52.2, (2021).
3. Gorgoretti Davide et al. „From track to digital twin: a machine learning and sensing approach to tire and steering system modeling.“ *Virtual Vehicle Symposium*, Graz, (2022).
4. Elkafafy, Mahmoud, et al. „Machine learning and system identification for the estimation of data-driven models: an experimental case study illustrated on a tire-suspension system.“ *Proceedings of ISMA*. (2020).
5. Kahneman, Daniel; Sibony, Olivier; Sunstein, Cass (16. Mai, 2021). *Noise: A Flaw in Human Judgment*. New York: Little, Brown Spark. ISBN 978-0-00-830899-5
6. Hendrickx, Kilian, et al. „A general anomaly detection framework for fleet-based condition monitoring of machines.“ *Mechanical Systems and Signal Processing* 139 (2020): 106585.
7. Lopes, Bernardo, et al. „Neural network models for the subjective and objective assessment of a propeller aircraft interior sound quality.“ *INTER-NOISE and NOISE-CON congress and conference proceedings*. Vol. 259. No. 5. Institute of Noise Control Engineering, 2019.

Siemens Digital Industries Software

Nord-, Mittel- und Südamerika: 1 800 498 5351

EMEA: 00 800 70002222

Asien-Pazifik: 001 800 03061910

Für weitere Nummern klicken Sie bitte [hier](#).

Über Siemens Digital Industries Software

Siemens Digital Industries Software fördert die Transformation von Unternehmen auf ihrem Weg in Richtung „Digital Enterprise“, in dem Engineering, Fertigung und Elektronikdesign bereits heute den Anforderungen der Zukunft entsprechen. Mit Siemens Xcelerator, dem umfassenden, integrierten Portfolio aus Software, Hardware und Services unterstützen wir Unternehmen jeder Größe bei der Entwicklung digitaler Zwillinge, die ihnen neue Einblicke, Möglichkeiten und Automatisierungsgrade bieten, um Innovationen voranzutreiben. Weitere Informationen über die Produkte und Leistungen von Siemens Digital Industries Software finden Sie unter siemens.com/software oder folgen Sie uns über [LinkedIn](#), [Twitter](#), [Facebook](#) und [Instagram](#).

siemens.com/software

© 2022 Siemens. Eine Liste wichtiger Warenzeichen von Siemens findet sich [hier](#). Alle anderen Marken sind Eigentum der jeweiligen Inhaber.

85027-D3-DE 1/23 LOC