

Dr.-Ing. Alexander Seidel | Dr.-Ing. Kevin Cremanns | Josef A. Overberg

# KI in der Produktentwicklung

Technologie, Praxiswissen und Anwendung



# INHALTSVERZEICHNIS



# KI in der Produktentwicklung

## Inhaltsverzeichnis

|                                                                                     |           |
|-------------------------------------------------------------------------------------|-----------|
| <b>TEIL 1: TECHNOLOGIE</b>                                                          | <b>16</b> |
| <b>1.1 KI ist überall – und jetzt auch in Ihrer Produktentwicklung</b>              | <b>17</b> |
| 1.1.1 Warum KI alles verändert – und warum das auch Sie betrifft                    | 17        |
| 1.1.2 LLM: Was Mainstream-Modelle können und was sie für Ingenieure (nicht) bringen | 18        |
| 1.1.3 Numerische KI: Das eigentliche Kraftpaket für die Industrie                   | 22        |
| 1.1.4 KI = Daten + Rechenpower + Algorithmen: Die drei Bausteine                    | 23        |
| <b>1.2 Neuronale Netze und Algorithmen – Das Gehirn der KI verstehen</b>            | <b>23</b> |
| 1.2.1 Das Fundament der KI: Der Aufbau neuronaler Netze                             | 24        |
| 1.2.2 Aktivierungsfunktionen: Das Feintuning der KI-Logik                           | 28        |
| <b>1.3 Wie KI lernt – und warum sie eigentlich nur gut rechnen kann</b>             | <b>33</b> |
| 1.3.1 Von Daten zu Vorhersagen: Der KI-Trainingsprozess                             | 33        |
| 1.3.2 Drei Wege zum Lernen: Muster, Anomalien und Versuch und Irrtum                | 35        |
| 1.3.3 Das Problem mit Overfitting – und wie man es verhindert                       | 39        |
| <b>1.4 Rechenleistung, Hardware &amp; Co.: Braucht meine KI einen Turbolader?</b>   | <b>40</b> |
| 1.4.1 Wie schnell lernt eine KI?                                                    | 41        |
| 1.4.2 CPU oder GPU? Was KI langsam macht und was sie beschleunigt                   | 42        |
| 1.4.3 Muss es High-End sein? Die Hardware-Anforderungen für KI                      | 44        |
| <b>1.5 Von der Theorie zur Praxis: Was es sonst noch zu wissen gibt</b>             | <b>46</b> |
| 1.5.1 Stärken und Schwächen im Überblick                                            | 46        |
| 1.5.2 Black-Box oder Glaskugel? Erkennen, ob eine KI richtig liegt                  | 49        |
| 1.5.3 On-Premise vs. On-Cloud: Datenschutz, Kosten und Skalierbarkeit               | 49        |
| 1.5.4 Open Source oder Lizenzmodell? Was sich wirklich lohnt                        | 50        |
| 1.5.5 Welche Technologie ist die richtige für Sie?                                  | 51        |

|                                                                                    |           |
|------------------------------------------------------------------------------------|-----------|
| <b>TEIL 2: DATEN</b>                                                               | <b>54</b> |
| <b>2.1 Warum Daten das Herzstück jeder KI sind</b>                                 | <b>55</b> |
| 2.1.1 Viel hilft viel? Wie viele Daten tatsächlich für das KI-Training nötig sind  | 55        |
| 2.1.2 Wovon die Anzahl der benötigten Daten abhängt – und wie Sie das herausfinden | 57        |
| 2.1.3 Die Theorie der Daten: Warum Sammeln allein nicht genügt                     | 61        |
| <b>2.2 Datenquellen im Überblick: Wo Daten herkommen</b>                           | <b>63</b> |
| 2.2.1 Verborgene Schätze: Vorhandene Datenquellen anzapfen                         | 63        |
| 2.2.2 Direkt ins Thema: Vor- und Nachteile vortrainierter KIs                      | 65        |
| <b>2.3 Wann lohnt sich der Einsatz von KI?</b>                                     | <b>66</b> |
| 2.3.1 Viele Daten = KI? Indizien für den Einsatz von KI                            | 66        |
| 2.3.2 Wann Künstliche Intelligenz wirklich entlastet                               | 67        |
| <b>2.4 Welche Daten KI verstehen – und nutzen – kann</b>                           | <b>70</b> |
| 2.4.1 Vollständigkeit, Modellgenauigkeit, Effizienz: Was gute Daten ausmacht       | 70        |
| 2.4.2 Datenqualität und -quantität: Die größten Mythen                             | 72        |
| <b>2.5 Datensammlung und -vorbereitung: So geht's richtig</b>                      | <b>74</b> |
| 2.5.1 Warum eine systematische Datensammlung das A und O ist                       | 74        |
| 2.5.2 Von Labeling bis Clustering: So schaffen Sie Ordnung im Datenchaos           | 75        |
| <b>2.6 Ab ins Training: Wie Sie Ihre KI „füttern“</b>                              | <b>80</b> |
| 2.6.1 Ein Blick ins Innere der KI: Was in der Black-Box passiert                   | 80        |
| 2.6.2 So läuft das KI-Training in der Realität                                     | 82        |
| <b>2.7 Mensch-Maschine-Dialog: So gelingt die Interaktion mit der KI</b>           | <b>85</b> |
| 2.7.1 Interaktion und Integration: Wie Sie auf die KI-Ergebnisse zugreifen         | 85        |
| 2.7.2 Warum Ihre Ergebnisse (nicht) gut sind – und was Sie verbessern können       | 87        |
| <b>2.8 Mit gepflegten Daten zur verlässlichen KI</b>                               | <b>89</b> |
| 2.8.1 Warum Datenpflege kein Nice-to-Have ist – und was das für Sie bedeutet       | 89        |
| 2.8.2 Wie systematisches Datenmanagement Ihre Workflows und Prozesse aufwertet     | 91        |
| <b>2.9 Von der Theorie zur Praxis: Was es sonst noch zu wissen gibt</b>            | <b>93</b> |
| 2.9.1 KI als Datengenerator – geht das?                                            | 93        |
| 2.9.2 Was ist ein KI-Agent – und welche Daten brauchen Sie dafür?                  | 94        |
| 2.9.3 Qualitätssicherung im Fokus: Kann KI auch Bilder verarbeiten?                | 95        |

|                                                                                   |            |
|-----------------------------------------------------------------------------------|------------|
| <b>TEIL 3: USE CASES</b>                                                          | <b>98</b>  |
| <b>3.1 Paradigmenwechsel: Wie die Produktentwicklung von KI profitiert</b>        | <b>99</b>  |
| 3.1.1 Welche Branchen bereits auf KI setzen – und warum                           | 99         |
| 3.1.2 Millionen-Invest oder Kleingeld?                                            | 103        |
| 3.1.3 Das V-Modell im KI-Zeitalter: Wo KI zum Einsatz kommt                       | 108        |
| <b>3.2 Requirements: Treffsichere Konzepte statt Bauchgefühl</b>                  | <b>110</b> |
| 3.2.1 Mit KI die erfolgreichsten Entwürfe ans Licht bringen                       | 112        |
| 3.2.2 Wissen im Unternehmen verfügbar machen                                      | 113        |
| <b>3.3 Design: Datenbasiert, kreativ und effizient</b>                            | <b>115</b> |
| 3.3.1 Neue Varianten und Topologien mit generativer KI simulieren                 | 115        |
| 3.3.2 Gute Ideen früh erkennen: Analytische KI als Entscheidungshilfe             | 118        |
| <b>3.4 Analyse: Ergebnisse auf den Punkt gebracht</b>                             | <b>121</b> |
| 3.4.1 Wie KI schnell stichhaltige Ergebnisse liefert                              | 123        |
| 3.4.2 Mit KI manuelle Arbeit reduzieren und Workflows automatisieren              | 127        |
| 3.4.3 LLMs als Sparringspartner für Simulationen                                  | 129        |
| <b>3.5 Prototyp und Test: Smarte Verknüpfung von virtueller und realer Welt</b>   | <b>130</b> |
| 3.5.1 Versuche effizienter gestalten: KI im Design of Experiments                 | 130        |
| 3.5.2 Wenn virtuelle und reale Daten Hand in Hand gehen                           | 133        |
| 3.5.3 Wissen demokratisieren: Mit KI die Versuchsauswertung unterstützen          | 134        |
| <b>3.6 Produktion, Betrieb und Service: Der Blick nach vorn</b>                   | <b>135</b> |
| 3.6.1 Wartung mit Weitblick: Anomalieerkennung und Predictive Maintenance         | 136        |
| 3.6.2 Das intelligente Produkt: Selbstlernende Systeme entwickeln                 | 138        |
| <b>3.7 Von der Theorie zur Praxis: Was es sonst noch zu wissen gibt</b>           | <b>139</b> |
| 3.7.1 KI als Entwicklungspartner: Wie KI den Produktentwicklungsprozess verändert | 139        |
| 3.7.2 Praxis-Tipps für Ihr erstes KI-Projekt                                      | 141        |

|                                                                               |            |
|-------------------------------------------------------------------------------|------------|
| <b>TEIL 4: IMPLEMENTIERUNG</b>                                                | <b>144</b> |
| <b>4.1 Von der Idee zur Realität – Vom Problem zur Lösung</b>                 | <b>145</b> |
| 4.1.1 So bringen Sie KI ins Unternehmen: Erste Schritte und Mindset           | 145        |
| 4.1.2 KI-Botschafter: Die treibende Kraft für Innovation                      | 148        |
| 4.1.3 Push oder Pull? Zwei Ansätze für Ihre KI-Strategie                      | 149        |
| <b>4.2 Planung ist die halbe Miete: Use Case als PoC definieren</b>           | <b>150</b> |
| 4.2.1 Ideen mit Impact: Workshops, Pain Points und Potenziale                 | 150        |
| 4.2.2 Von Potenzialen zu Prioritäten: Anwendungsfälle bewerten und auswählen  | 152        |
| 4.2.3 Von Zahlen, Zeit und Zielen: Budget, Ressourcen und KPIs im Griff       | 156        |
| <b>4.3 Durchführung des PoC: Klein starten, groß denken</b>                   | <b>158</b> |
| 4.3.1 Make, Buy oder Hybrid? Die Qual der Wahl                                | 158        |
| 4.3.2 Der PoC in der Praxis: Umsetzung mit Plan                               | 159        |
| 4.3.3 Dokumentation nicht vergessen: Erfahrungen bewahren                     | 161        |
| <b>4.4 Evaluierung des PoC: Schneller, besser, weiter?</b>                    | <b>163</b> |
| 4.4.1 KPIs und Meilensteine: So messen Sie echten Fortschritt                 | 163        |
| 4.4.2 Lessons Learned: Nachhaltig Mehrwert schaffen                           | 164        |
| 4.4.3 Entscheidungen treffen: War der PoC ein Erfolg – und was, wenn nicht?   | 166        |
| <b>4.5 Skalierung und Betrieb: KI im Unternehmen verankern</b>                | <b>168</b> |
| 4.5.1 Vom PoC zum Produktivbetrieb: So gelingt der Rollout                    | 169        |
| 4.5.2 Statisch oder dynamisch? Betriebsstrategien für KI-Modelle              | 171        |
| 4.5.3 Machine Learning Operations: Damit Ihre KI unter Kontrolle bleibt       | 173        |
| <b>4.6 Rechtliche Spielregeln: Was Sie wissen sollten</b>                     | <b>178</b> |
| 4.6.1 EU AI Act: Über Risikoklassifizierung und Benutzerklassen               | 178        |
| 4.6.2 DSGVO: Wenn persönliche Daten in der Produktentwicklung relevant werden | 181        |
| <b>4.7 Von der Theorie zur Praxis: Was es sonst noch zu wissen gibt</b>       | <b>181</b> |
| 4.7.1 Praxistipps aus der Erfahrungskiste: Was Sie unbedingt beachten sollten | 181        |
| 4.7.2 Blick nach vorn: Momentum nutzen und dranbleiben                        | 182        |
| 4.7.3 Checkliste-to-Go: An was Sie denken sollten – kurz und kompakt          | 183        |

|                                                                                       |            |
|---------------------------------------------------------------------------------------|------------|
| <b>TEIL 5: MENSCH &amp; KI</b>                                                        | <b>186</b> |
| <b>5.1 Ingenieure, aufgepasst: Die Zukunft klopft an</b>                              | <b>187</b> |
| 5.1.1 Ingenieure & KI: Das neue Dreamteam in der Produktentwicklung                   | 188        |
| 5.1.2 Zukunft gestalten: Warum Ingenieure jetzt gefragt sind                          | 190        |
| <b>5.2 Vom Zeichenbrett bis zur KI: Die Rolle des Ingenieurs im Wandel</b>            | <b>192</b> |
| 5.2.1 Die Zeichenbrett-Ära (bis ca. 1970)                                             | 192        |
| 5.2.2 Die CAD- und Simulations-Ära (ab ca. 1970)                                      | 193        |
| 5.2.3 Die Daten- und Automatisierungs-Ära (ab heute)                                  | 195        |
| <b>5.3 Was heute schon geht: Ingenieurskunst im Zeitalter von KI</b>                  | <b>198</b> |
| 5.3.1 Warum der Mensch die letzte Entscheidung trifft                                 | 198        |
| 5.3.2 Synergie statt Substitution: Zusammenarbeit neu gedacht                         | 201        |
| 5.3.3 Von Ethik und Verantwortung                                                     | 203        |
| <b>5.4 Die nächste Evolutionsstufe: Harmonische Kollaboration von Mensch &amp; KI</b> | <b>207</b> |
| 5.4.1 Die Zukunft gehört den Spezialisten – auch in der KI                            | 207        |
| 5.4.2 Externe Tools und Multi-Agenten-Systeme                                         | 208        |
| <b>5.5 Der Weg zur Co-Intelligenz: Kompetenzen entwickeln, Wandel gestalten</b>       | <b>210</b> |
| 5.5.1 Upskilling & Reskilling: Müssen Ingenieure zu KI-Experten werden?               | 211        |
| 5.5.2 Change Management: KI erfolgreich im Unternehmen verankern                      | 214        |
| <b>5.6 Von der Theorie zur Praxis: Was es sonst noch zu wissen gibt</b>               | <b>217</b> |
| 5.6.1 Ersetzt KI zukünftig den Ingenieur?                                             | 217        |
| 5.6.2 Vier Keyfacts: Damit Ihre KI-Strategie zum Erfolg wird                          | 219        |

# TECHNOLOGY



## Teil 1: Technologie

### Zauberei oder doch nur Rechenkunst? Was wirklich hinter KI steckt

|            |                                                                               |           |
|------------|-------------------------------------------------------------------------------|-----------|
| <b>1.1</b> | <b>KI ist überall – und jetzt auch in Ihrer Produktentwicklung</b>            | <b>17</b> |
| 1.1.1      | Warum KI alles verändert – und warum das auch Sie betrifft                    | 17        |
| 1.1.2      | LLM: Was Mainstream-Modelle können und was sie für Ingenieure (nicht) bringen | 18        |
| 1.1.3      | Numerische KI: Das eigentliche Kraftpaket für die Industrie                   | 22        |
| 1.1.4      | KI = Daten + Rechenpower + Algorithmen: Die drei Bausteine                    | 23        |
| <b>1.2</b> | <b>Neuronale Netze und Algorithmen – Das Gehirn der KI verstehen</b>          | <b>23</b> |
| 1.2.1      | Das Fundament der KI: Der Aufbau neuronaler Netze                             | 24        |
| 1.2.2      | Aktivierungsfunktionen: Das Feintuning der KI-Logik                           | 28        |
| <b>1.3</b> | <b>Wie KI lernt – und warum sie eigentlich nur gut rechnen kann</b>           | <b>33</b> |
| 1.3.1      | Von Daten zu Vorhersagen: Der KI-Trainingsprozess                             | 33        |
| 1.3.2      | Drei Wege zum Lernen: Muster, Anomalien und Versuch und Irrtum                | 35        |
| 1.3.3      | Das Problem mit Overfitting – und wie man es verhindert                       | 39        |
| <b>1.4</b> | <b>Rechenleistung, Hardware &amp; Co.: Braucht meine KI einen Turbolader?</b> | <b>40</b> |
| 1.4.1      | Wie schnell lernt eine KI?                                                    | 41        |
| 1.4.2      | CPU oder GPU? Was KI langsam macht und was sie beschleunigt                   | 42        |
| 1.4.3      | Muss es High-End sein? Die Hardware-Anforderungen für KI                      | 44        |
| <b>1.5</b> | <b>Von der Theorie zur Praxis: Was es sonst noch zu wissen gibt</b>           | <b>46</b> |
| 1.5.1      | Stärken und Schwächen im Überblick                                            | 46        |
| 1.5.2      | Black-Box oder Glaskugel? Erkennen, ob eine KI richtig liegt                  | 49        |
| 1.5.3      | On-Premise vs. On-Cloud: Datenschutz, Kosten und Skalierbarkeit               | 49        |
| 1.5.4      | Open Source oder Lizenzmodell? Was sich wirklich lohnt                        | 50        |
| 1.5.5      | Welche Technologie ist die richtige für Sie?                                  | 51        |

## 1.1 KI ist überall – und jetzt auch in Ihrer Produktentwicklung

Am Anfang eine nüchterne Feststellung: Schauen Sie sich um, Künstliche Intelligenz (KI) ist überall. Sie bremst Ihr Auto und parkt es ein, schlägt Ihnen Produkte und Filme vor, die Ihnen gefallen, dimmt das Wohnzimmerlicht und schreibt blumige Geburtstagswünsche. Auch im Job ist sie da: In den meisten Branchen arbeitet Künstliche Intelligenz inzwischen auf die eine oder andere Weise mit. Sie hilft rasend schnell, große Datenmengen zu analysieren, automatisiert Produktionsprozesse und erkennt – schneller als jeder Mensch – Ausschuss und Betrugsfälle sieben Meilen gegen den Wind. Und vieles mehr.

### 1.1.1 Warum KI alles verändert – und warum das auch Sie betrifft

War Künstliche Intelligenz noch vor ein paar Jahren ein Spezialgebiet von Techies, ist sie heute im ganz normalen Alltag angekommen. Die zunehmende Präsenz in allen Lebensbereichen setzt viele Menschen unter Druck: Wer jetzt noch ohne KI arbeitet, hat oft Angst etwas zu verpassen – und in der Folge wirtschaftlich den Anschluss zu verlieren. Das ist besonders unangenehm, wenn man plötzlich entscheiden soll, wo und wie KI in einem Unternehmen eingesetzt wird, aber noch nicht so recht versteht, wie sie funktioniert. Falls es Ihnen auch so geht: Damit sind Sie nicht allein.



#### Warum sollte sich jedes Unternehmen dem Thema KI stellen?

Wie heißt es so schön: Die Konkurrenz schläft nicht. Unternehmen, die KI-Technologien gezielt in ihre Entwicklungsprozesse integrieren, gewinnen einen enormen Vorsprung in Effizienz, Innovationskraft und Wettbewerbsfähigkeit.

Bevor Sie also KI-gestützte Lösungen in der Produktentwicklung einsetzen, ist es wichtig zu verstehen, wie sie funktioniert – und welche

Faktoren sie beeinflussen. Denn KI ist nicht gleich KI. Manche Modelle eignen sich für bestimmte Aufgaben hervorragend, für andere hingegen überhaupt nicht. Welche das jeweils sind und welche Technologien dahinterstecken, erfahren Sie in Teil 1 dieses Buches.

Wenn Sie also der Meinung sind, erst noch mehr über KI wissen zu müssen, bevor Sie eventuell Geld dafür ausgeben, dann sind Sie hier goldrichtig. Genauso, wenn Sie unsicher sind, ob Sie KI in Ihrem Unternehmen überhaupt sinnvoll einsetzen können. Oder wenn Sie wissen wollen, welche Hardware Sie sich dafür zulegen sollten. Wenn Ihnen jemand nahegelegt hat, sich bitte mal über Maschinelles Lernen schlau zu machen. Und auch, wenn Sie sich dafür interessieren, welche Hyperparameter neuronale Netze bestimmen und was gegen Overfitting hilft.



### Muss ich das alles verstehen?

Wir wollen Licht ins Dunkel der Black-Box KI bringen und Sie dabei unterstützen, auf das richtige Pferd zu setzen. Eine gute Nachricht: Sie müssen nicht alle technologischen Grundlagen bis ins kleinste Detail durchdringen. In der Praxis gibt es Lösungen, die diese Grundlagen perfekt beherrschen und Ihnen die Arbeit abnehmen.

## 1.1.2 LLM: Was Mainstream-Modelle können und was sie für Ingenieure (nicht) bringen

Bevor wir nun tiefer einsteigen: Beginnen wir mit einem Beispiel aus dem täglichen Leben, anhand dessen wir Ihnen die verschiedenen Bestandteile der KI erklären. Stellen Sie sich vor, wir kochen Kartoffeln. Die Garzeit einer Kartoffel hängt von verschiedenen Faktoren ab, wie zum Beispiel der Größe und Sorte der Kartoffel, der Temperatur der Herdplatte, der Wassermenge und so weiter. Nun wollen wir einer KI beibringen, dass sie uns – abhängig von diesen Parametern – die Garzeit vorhersagt.

Welche Art von KI können wir für diese Aufgabe nutzen? Die Größe der Kartoffel, die Temperatur der Herdplatte, die Wassermenge und alle anderen Parameter werden in Zahlen ausgedrückt, es sind keine Textinformationen. Daher wird ein sogenanntes Large Language Model (LLM) für uns wahrscheinlich nicht die richtige Wahl sein.

Das bedeutet aber nicht, dass LLMs für Ingenieure generell uninteressant sind. LLMs wie ChatGPT beziehungsweise GPT, Gemini, LLaMa und DeepSeek basieren auf Text. Sie sind vergleichsweise einfach zu nutzen: Sie als Nutzer stellen dem Tool eine Frage und erhalten eine Antwort – beides in natürlicher Sprache. Hierfür lernt das Sprachmodell eine statistische Verteilung sogenannter Tokens. Dabei handelt es sich um Vektoren von Zahlen, die etwa einzelne Silben oder Bruchstücke von Worten repräsentieren – typischerweise so, dass mit möglichst wenig Tokens möglichst viel Text abgebildet werden kann.

Wenn Sie eine Frage stellen, überprüft das Modell Wort für Wort, welche Aneinanderreihung der Tokens statistisch gesehen die wahrscheinlichste ist. Ein LLM versteht also nicht wirklich, was es antwortet; hinter seiner Arbeit steckt reine Statistik. Das ist auch ein Grund, warum es keine physikalischen Zusammenhänge abbilden, stattdessen allerdings „halluzinieren“ kann. Dabei wird ein Wort oder Satz ausgegeben, der statistisch gesehen mit hoher Wahrscheinlichkeit an dieser Stelle folgerichtig ist – auch wenn er tatsächlich inhaltlich falsch ist oder keinen Sinn ergibt.



### Gut zu wissen

Jede KI arbeitet mit Zahlen. Auch wenn es so scheint, dass eine KI sehen, lesen, hören oder sogar neue Musik komponieren kann, werden alle diese Daten – also Texte, Bilder, Audio – in Zahlen umgewandelt. Erst dann kann die KI etwas damit anfangen. Das hängt damit zusammen, wie eine KI trainiert und vorhersagt.

Ein Bild besteht aus Pixeln, bei der eine Zahl die Farbe des Pixels repräsentiert. Bei Videos handelt es sich um viele aneinandergereihte Bilder. Und Text wird in Tokens umgewandelt.

Das ist auch der Grund, warum LLMs wie ChatGPT und Co. nicht gut mit Zahlen umgehen können. In Sprachmodellen werden Zahlen zwar als Tokens verarbeitet, jedoch wie Wörter behandelt. Dadurch fehlt ihnen eine echte mathematische Interpretation. Deswegen sind LLMs grundsätzlich schlecht darin, numerische oder physikalische Zusammenhänge genau zu modellieren.

Im Unternehmenskontext eignen sich LLMs unter anderem gut dafür, Informationen zu organisieren und verfügbar zu machen. Sie fassen Datenmengen zusammen, schreiben Programme für technische Berechnungen, erstellen Tutorials und mehr. Das ist nicht nur, aber auch für die Produktentwicklung praktisch. Suchen Sie in Ihrem Betrieb nach bereits entwickelten Produkten mit ganz bestimmten Eigenschaften und wollen wissen, welche Versuche bei der Entwicklung durchgeführt wurden, finden LLMs das schneller als jeder Mensch heraus. Sprachmodelle unterstützen Sie auch dabei, Engineering-Prozesse wie die CAD-Modellierung zu automatisieren und Produktionsabläufe zu optimieren. Generell eignen sich LLMs auch für jegliche Supportaufgaben, bei denen es darum geht, textbasierte Fragen zu beantworten.



### Wichtig zu wissen

Die einzelnen LLMs unterscheiden sich teilweise stark voneinander. Es gibt Generalisten wie ChatGPT und Gemini, die sich besonders für das breite Spektrum der Text- und Codegenerierung eignen, und Spezialisten wie Baidus ERNIE, das für die chinesische Sprache, Wissensintegration und technische Anwendungen optimiert ist.

Die Sprachmodelle sind unterschiedlich komplex gebaut und basieren auf unterschiedlichen Trainingsdaten. Einige Modelle brauchen erhebliche Rechenressourcen; sie sind vergleichsweise genau, aber teuer. Andere sind hingegen hocheffizient, günstiger und vielleicht nicht ganz so präzise, antworten dafür aber schneller. Das hängt mit der Größe und der Anzahl der Parameter in diesen Modellen zusammen – darauf gehen wir später noch ein.

Eine wichtige Weiterentwicklung moderner Sprachmodelle sind die sogenannten LLM-Agenten, die selbstständig Aufgaben übernehmen. Diese können Sie zum Beispiel damit beauftragen, eine Reise zu buchen oder etwas im Onlinekaufhaus zu bestellen. Dabei beantworten die Sprachmodelle nicht mehr nur einfache Fragen, sondern planen mehrstufige Abläufe automatisiert und arbeiten diese ab. Das ist auch für die Produktentwicklung interessant. Zum Beispiel könnten Sie den Agenten bitten, die Daten der letzten Produktserie zu untersuchen, anschließend die häufigsten Gründe für Rückläufer in einem Bericht zusammenzufassen und schließlich für die Besprechung ein Meeting mit allen Stakeholdern anzuberaumen.

Aber zurück zu unseren Kartoffeln. Wenn wir nun keine LLMs dafür einsetzen können, weil diese nicht gut mit Zahlen umgehen können und keine Physik verstehen: Was können wir stattdessen verwenden? Für die Antwort müssen wir noch einmal etwas ausholen.

Wir wissen bereits: Jede KI arbeitet mit Zahlen. Der Unterschied liegt oft in der Datenvorverarbeitung, je nachdem, ob die KI auch mit Bildern, Text oder Audio trainiert werden soll. Ein Beispiel dafür ist das Erstellen der Tokens – ein Schritt, bei dem Text in Zahlen umgewandelt wird und der vor dem eigentlichen Trainieren der KI stattfindet. Hinter allen LLMs steckt dabei ein bestimmter KI-Algorithmus: neuronale Netze. Statt mit Tokens können diese allerdings auch direkt mit Zahlen trainiert werden – und eignen sich dann sehr gut für unsere Kartoffeln.

Im Folgenden bezeichnen wir eine KI, die im Gegensatz zu LLMs direkt auf Zahlen arbeitet, als numerische KI. Die numerische KI ist der eigentliche KI-Star in der Produktentwicklung. Im Allgemeinen ist diese Art aber weniger bekannt als die Sprachmodelle.



## Warum ist der Unterschied wichtig?

Viele assoziieren KI mit Chatbots und Textgeneratoren. Doch für die Produktentwicklung ist vor allem numerische KI spannend – denn sie arbeitet mit Daten und Mustern und kann physikalische Zusammenhänge lernen. Wenn Sie den Unterschied kennen, können Sie besser einschätzen, welches Modell für Ihre Aufgaben geeignet ist.

### 1.1.3 Numerische KI: Das eigentliche Kraftpaket für die Industrie

Numerisch basierte KI kann Zusammenhänge in Daten erlernen. Dadurch ist sie sehr vielfältig in der Entwicklung einsetzbar. Ihre Stärken liegen in der Automatisierung, Optimierung, Vorhersage und in der datengetriebenen Innovation.

Ein paar Beispiele dafür, was diese KI für die Produktentwicklung leisten kann:

- Produktionsabläufe automatisieren, steuern und optimieren.
- Anomalien und Fehler in Fertigungsprozessen oder Bauteilen mittels Bild- und Sensordaten in Echtzeit erkennen.
- Simulationen rasant beschleunigen – und zwar von Stunden oder Tagen auf wenige Sekunden. Spoiler: KI kann aufwendige Finite-Elemente-Simulationen (FEM) oder Computational Fluid Dynamics (CFD) ergänzen oder sogar ersetzen.

Halten wir erst einmal fest: KI, die mit numerischen Daten arbeitet, hat ein viel breiteres Einsatzspektrum in der Produktentwicklung als Sprachmodelle.

### 1.1.4 KI = Daten + Rechenpower + Algorithmen: Die drei Bausteine

Künstliche Intelligenz mag auf den ersten Blick wie Magie wirken, doch in Wirklichkeit steckt dahinter eine klare Formel. Drei Bausteine bilden das Fundament jeder KI-Anwendung – von der Bildverarbeitung bis zur Simulation komplexer physikalischer Prozesse:

- **Daten** sind das Rohmaterial, aus dem KI lernt und mit dem sie arbeiten kann.
- **Algorithmen** sind das „Gehirn“ der KI. Sie bestimmen, wie Daten verarbeitet, Muster erkannt und Entscheidungen getroffen werden.
- **Rechenpower** sorgt dafür, dass komplexe Berechnungen in vertretbarer Zeit durchgeführt werden können. Ohne sie wären moderne KI-Modelle praktisch nutzlos.

Diese drei Elemente sind untrennbar miteinander verbunden. Ohne Daten kein Lernen, ohne Algorithmen keine Intelligenz, ohne Rechenleistung keine Praxisanwendung. Wer KI erfolgreich einsetzen will, sollte alle drei Bausteine im Blick behalten.

## 1.2 Neuronale Netze und Algorithmen – Das Gehirn der KI verstehen

Wir haben eingangs schon kurz darüber gesprochen: Neuronale Netze sind der KI-Algorithmus hinter den LLMs und können auch als numerische KI eingesetzt werden. Als einer der weitverbreitetsten Algorithmen stecken sie hinter den meisten industriellen KI-Anwendungen. Zu ihren Vorteilen gehören ihre Skalierbarkeit für große Datenmengen, ihr effizientes Training und ihre Fähigkeit, mit unterschiedlichen Datenformen wie Text, Audio und Video umzugehen – eine Eigenschaft, die nur wenige Algorithmen besitzen. Das ist auch auf die umfangreiche Forschung auf diesem Gebiet zurückzuführen.

Aber schauen wir doch zunächst einmal, was neuronale Netze eigentlich sind, und wie sie aufgebaut sind.

### 1.2.1 Das Fundament der KI: Der Aufbau neuronaler Netze

Wie der Name schon sagt, ist ein neuronales Netz ein Netz aus miteinander verbundenen Neuronen. Die Funktionsweise ähnelt der unseres Gehirns. Dort werden Informationen als elektrische Impulse über die Nervenbahnen an Neuronen weitergeleitet oder nicht – das ist abhängig davon, ob der Impuls einen gewissen Schwellenwert überschreitet. So ähnlich funktionieren auch neuronale Netze.

Fangen wir erst einmal mit dem Grundbaustein an: dem Neuron. Nehmen wir dafür wieder unser Kartoffelbeispiel.

Wir haben festgestellt, dass mehrere Parameter – wie die Größe der Kartoffel, Temperatur der Herdplatte, Wassermenge und so weiter – einen Einfluss auf die Garzeit haben. Jetzt könnten wir überlegen, inwiefern die Garzeit etwa von der Größe der Kartoffel und der Wassermenge abhängt. Vielleicht lässt sich die Abhängigkeit mit einer Gleichung darstellen:

$$\text{Garzeit} = \text{Größe der Kartoffel} * 0,5 + \text{Wassermenge} * 3 + 2$$

Das würde man in der Mathematik als lineares Modell bezeichnen und ist das einfachste KI-Modell, das man sich vorstellen kann. Was die 0,5, die 3 und die 2 bedeuten, erklären wir später.

Gleichzeitig ist dieses lineare Modell auch die Definition eines Neurons in einem neuronalen Netz. Ein Neuron bekommt Informationen, wie in diesem Beispiel die Größe der Kartoffel und die Wassermenge, und verarbeitet diese Eingangsinformationen, indem es sie mit bestimmten Faktoren addiert und multipliziert. Dann gibt das Neuron eine neue Zahl als Ergebnis aus.

Um aus einem einzelnen Neuron ein Netz zu machen, können wir mehrere Neuronen miteinander verbinden, etwa indem wir zwei Neuronen hintereinanderschalten. Das ergäbe so etwas wie:

$$\text{Zwischenergebnis} = \text{Größe der Kartoffel} * 0,5 + \text{Wassermenge} * 3 + 2$$

Das Zwischenergebnis geht dann als Eingangsinformation in ein weiteres Neuron:

$$\text{Garzeit} = 4 * \text{Zwischenergebnis} + 5$$

So können Neuronen immer weiter miteinander verschachtelt werden und ein Netz bilden.

Warum ist das notwendig? Gegebenenfalls ist die Vorhersage der Garzeit so komplex, dass ein einzelnes lineares Modell dafür nicht ausreicht. Umso mehr Neuronen sich in unserem Netz befinden, desto komplexere Zusammenhänge können wir damit abbilden.

### Feedforward-Netz

