Machine Learning in der Qualitätssicherung

Intelligente Werkzeuge per Machine Learning

Die Problematik

Die Qualität eines Produktes ist die Summe vieler einzelner Produktions- und Montageschritte, die möglichst fehlerfrei und stabil innerhalb eines geringen Toleranzbereichs ausgeführt werden müssen. Eine einzelne Schraube, die mit dem falschen Drehmoment angezogen wurde oder ein vor der Verarbeitung unzureichend temperierter Werkstoff reichen aus, um ein fehlerhaftes Produkt zu erzeugen. Das gleiche gilt für Alterungsprozesse und die Abnutzung von Werkzeugen, die Werkstücke mit kritischen Toleranzen und letztendlich fehlerhafte Produkte erzeugen. Häufig fallen Toleranzbedingte Produktfehler in der Endkontrolle überhaupt nicht auf. Das Produkt wird ausgeliefert und verursacht in einem Worst-Case-Szenario dann innerhalb der Garantie- und Gewährleistungszeit einen unerfreulichen Kundenkontakt.

Der Lösungsansatz

Mit einer entsprechenden Sensorik, Nahbereichsfunkschnittstellen und speziellen Machine-Learning-Algorithmen lassen sich die Produktionsschritte in Echtzeit überwachen, um die zuvor angesprochenen Fehler und andere Ursachen sofort zu erkennen. Nun ist die Werkzeug- und Produktionsüberwachung mit Hilfe IT-gestützter Systeme an sich nichts neues. Auf Grund der hohen Kosten für geeignete Sensoren und bedingt durch die klassische Regelbasierte Software zur Fehlerkennung war und ist die Erkennungsquote mehrdimensionaler Problemursachen aber alles andere als ausgereift – die zahlreichen Rückrufe der vergangenen Jahre dürften diese These bestätigen.

Sensoren und KI

Im Bereich der Sensorik hat sich den vergangenen Jahren einiges getan. MEMS- und andere mikroelektronische Sensoren sind zum Beispiel inzwischen derart leistungsfähig, preiswert und in kleinsten Bauformen verfügbar, dass sie sich sogar direkt in einen Akkuschrauber oder andere Werk-

Kurz gefasst

Integriert man ein geeignetes Embedded System und die passenden Algorithmen zusammen mit der entsprechenden Sensorik in ein Werkzeug, entsteht eine intelligente Variante, die per maschinellem Lernen anhand von Sensordatenmustern den Werkzeugeinsatz in Echtzeit überwachen kann.

Autor:
Klaus-Dieter Walter,
CEO bei
SSV Software Systems GmbH
www.ssv-embedded.de

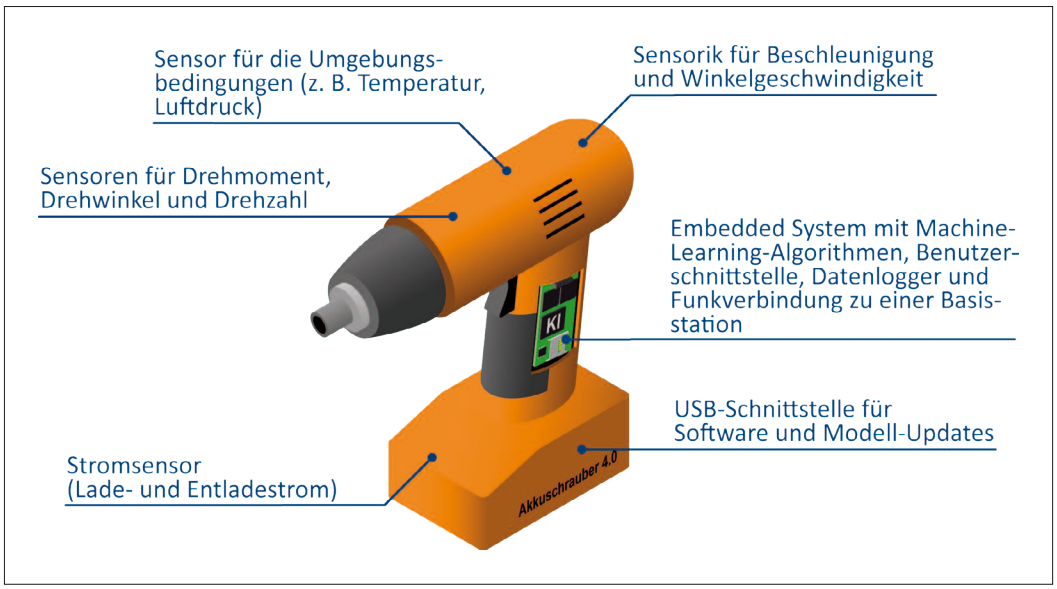

Bild 1: Bedingt durch die Innovationen im Bereich der Halbleitersensorik, Embedded Systems und bei den Algorithmen zum maschinellen Lernen lassen sich inzwischen intelligente Werkzeuge herstellen, die beispielsweise die Montageschritte in Echtzeit überwachen und mit Hilfe von zuvor antrainierten Toleranzklassen die Qualität bewerten

zeuge integrieren lassen. Darüber hinaus wird gegenwärtig dem Einsatz künstlicher Intelligenz (KI) und besonders des zu diesem Thema gehörenden maschinellen Lernens (Machine Learning) auch für Anwendungen im Bereich der Qualitätssicherung ein sehr großes Innovationspotenzial zugetraut. In Hinblick auf die Werkzeugüberwachung bedeutet das völlig neue Softwareeigenschaften, da die Bewertung der erfassten Produktions- und Montagedaten nicht mehr anhand expliziter Regeln und lexikalischen Wissens, das manuell in Software kodiert wurde, erfolgen muss. Stattdessen lassen sich Machine-Learning-Algorithmen nutzen, die zunächst aus vorhandenen (Historien-) Daten lernen und anschließend in Echtzeit den Einsatz eines Werkzeugs überwachen können.

Variantenvielfalt des maschinellen Lernens

Da die wesentlichen Grundlagen der künstlichen Intelligenz und des maschinellen Lernens aus den 50er Jahren stammen, gibt es mittlerweile eine schwer überschaubare Algorithmenvielfalt. Die Cloud-Anbieter konzentrieren sich zurzeit in erster Linie auf Algorithmen für Supervised Machine Learning, ganz besonders auf das sogenannte Deep Learning mit künstlichen neuronalen Netzen. Insgesamt lässt sich das maschinelle Lernen in drei Bereiche gliedern:

Supervised Learning

Überwachtes maschinelles Lernen. Die meisten der gegenwärtig in der Praxis genutzten Machine-Learning-Algorithmen, wie zum Beispiels CNNs (Convolutional Neural Networks) gehören zu dieser Kategorie. Bei diesem Verfahren ist der Zusammenhang zwischen den Eingangs- und Ausgangsgrößen an Hand von Historiendaten im Vorfeld bekannt. Insofern haben wir es mit einem Mapping der Eingangsdaten auf den Ausgang zu tun, wie es auch bei unzähligen klassischen Embedded-System-Programmieraufgaben der Fall ist. Der jeweils zum Einsatz kommende Algorithmus muss zunächst trainiert werden. Dabei entsteht ein Modell. Für die Trainingsphase werden gelabelte (Historien-) Daten benötigt. Bei einer sinnvollen Abstimmung zwischen den Daten und dem jeweils gewählten Algorithmus sowie einer ausreichenden Trainingsdatenmenge von guter Qualität lassen sich anschließend an Hand bisher unbekannter Datenwerte relativ genaue diskrete Klassifizierungs- oder kontinuierliche Regressionswerte vorhersagen. Typische Anwendungsbeispiele für überwachtes Lernen sind die Objekterkennung in Bilddaten (Mustererkennung) und die Vorhersage des Energiebedarfs einer Maschine. Die in der Trainingsphase des Supervised Machine Learnings entstehenden Modelle sind statisch und müssen bei Bedarf durch ein erneutes Training an veränderte Bedingungen angepasst werden.

Unsupervised Learning

Unüberwachtes maschinelles Lernen. Dieses Verfahren wird bei Bedarf auf Daten mit unbekannten Zusammenhängen angewendet, um

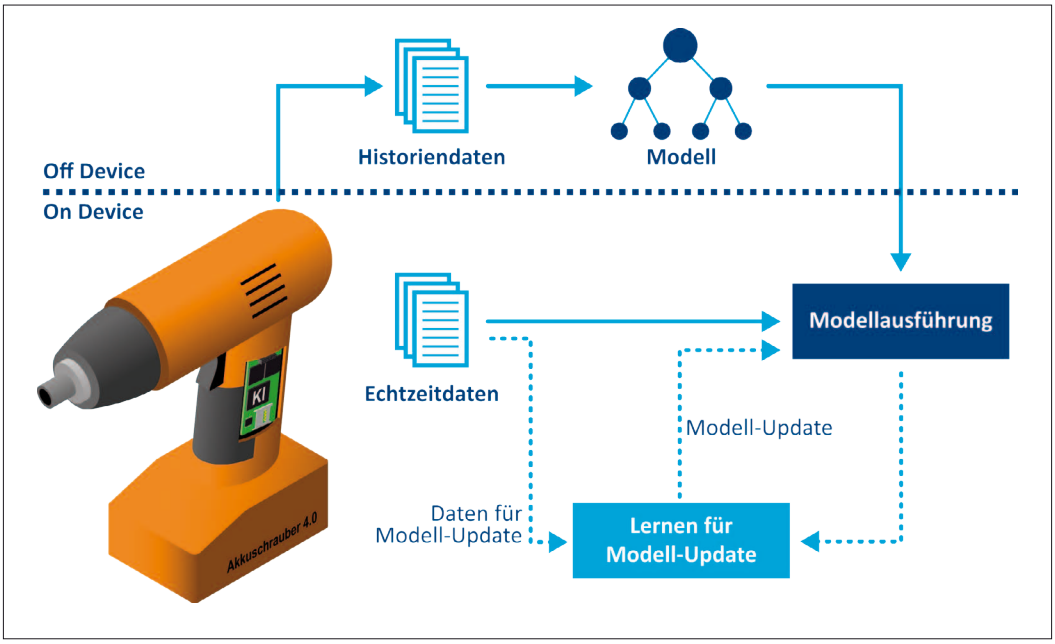

Bild 2: Der Einsatz eines intelligenten Akkuschraubers mit integrierten Machine-Learning-Algorithmen zur Qualitätssicherung erfolgt in zwei Phasen. In einer Trainingsphase wird aus den von Akkuschraubern zuvor erzeugten Historiendaten ein geeignetes Modell erzeugt, um die Qualität der Schraubvorgänge entsprechend zu klassifizieren. Dieser Schritt erfolgt auf Grund der benötigten Ressourcen außerhalb des Akkuschraubers (Off Device), z. B. auf einem leistungsfähigen PC. Die zweite Phase ist die Modellnutzung durch das Embedded System des Akkuschraubers (On Device), um an Hand der Echtzeitdaten zu entscheiden, ob ein Montagsschritt OK oder nicht OK war. Um die bestmögliche Qualität sicherzustellen, ist zusätzlich ein „Modell-Update-Prozess" vorzusehen, der zu inkrementellen Modellverbesserungen im Akkuschrauber führt

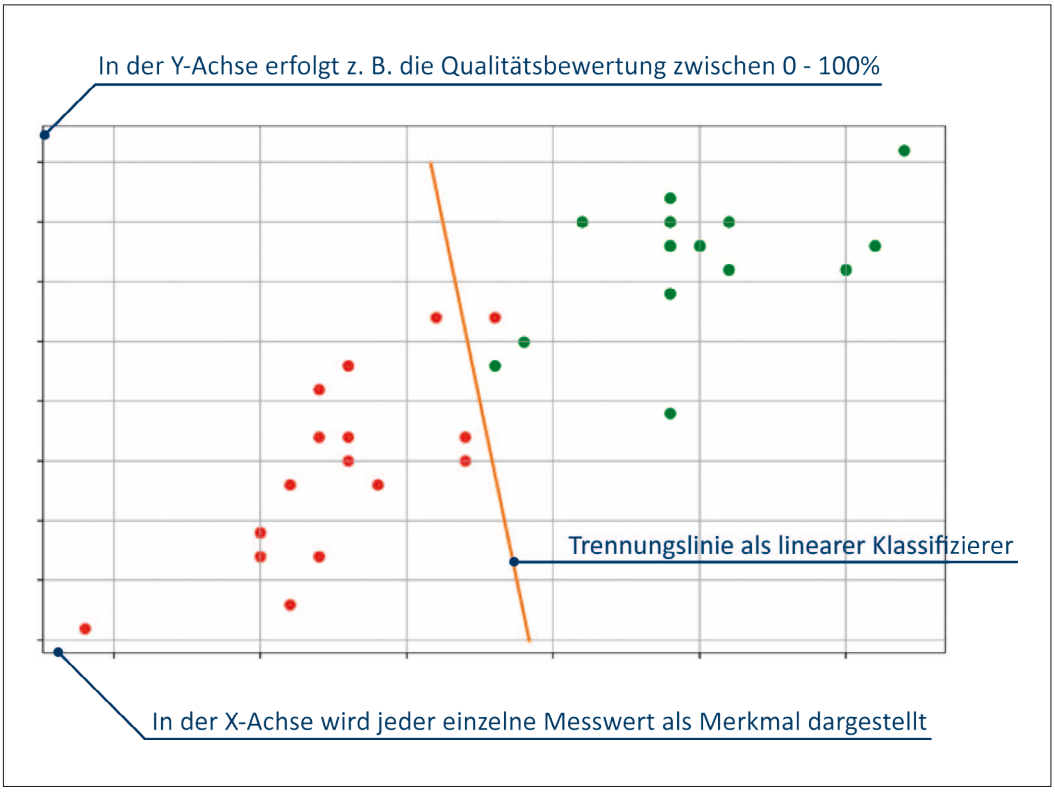

Bild 3: Vereinfacht, also mit einem einzigen (eindimensionalen) Messwert, lässt sich eine Sensordatenqualifizierung wie folgt darstellen: In der X-Achse wird der jeweilige Messwert als Merkmal dargestellt. Die Y-Achse bildet dann z. B. die Qualitätsbewertung aus dem Bereich 0 bis 100%. Daraus könnte ein Klassifizierungsalgorithmus ein Modell erstellen, um anschließend bisher unbekannte Messwerte in Gut (Grün) oder Schlecht (Rot) zu klassifizieren. In einem Akkuschrauber würde der Messwert nicht aus einem einzigen Merkmal, sondern stattdessen aus mehr als 10 verschiedenen Merkmalen (z. B. Drehmoment, 3-Achsen-Drehwinkel, Strom, 3-Achsen-Beschleunigung, 3-Achsen-Winkelgeschwindigkeit usw.) bestehen. Jedes Merkmal bildet eine Dimension

in den Eingangsdaten mit Rechnerunterstützung nach Mustern (Clustern) und den Grenzen zwischen den gefundenen Clustern zu suchen. Insofern spricht man bei dieser Kategorie des maschinellen Lernens auch häufig von Clusteranalysen, also die Zuordnung der vorliegenden Datenpunkte zu bestimmten Gruppen (den Clustern). Die in der Mathematik zur Verfügung stehenden Methoden nutzen unterschiedliche Ansätze, wie z. B. das prototypische Bilden von Cluster-Zentren in einem n-dimensionalen kontinuierlichen Raum (K-means-Methodik) oder Dichte-basierte Regionen als Zentrum eines möglichen Clusters (DBSCAN-Algorithmus). Darüber hinaus gibt es auch noch hierarchische Clusterverfahren. Die gefundenen Ähnlichkeitsstrukturen und die per Clusteranalyse festgelegten Gruppen können in der Praxis als Vorlage zum Labeln der bisher unbekannten Daten für ein anschließendes Supervised Machine Learning dienen.

Reinforcement Learning

Bestärkendes maschinelles Lernen. Beim Reinforcement Learning (RL) steht die Interaktion eines lernenden Agenten mit seiner Umwelt im Mittelpunkt. Mit Hilfe des RL können Computer nicht nur Brettspiele wie Schach oder Go gewinnen. Diese Methodik des maschinellen Lernens spielt inzwischen auch für Embedded Systeme in der Robotik und bei autonom agierenden Logistiksystemen, z. B. vollautonome Flurförderzeuge wie Gabelstapler eine sehr wichtige Rolle. Des Weiteren nutzen Staubsaug- oder Rasenmähroboter im Haus oder Garten beispielsweise den zum RL gehörenden Q-Learning-Algorithmus, um ohne fremde Hilfe den Weg zur Ladestation zu finden usw. Die Zusammenhänge beim RL sind relativ einfach: Die Umwelt des Agenten, die von diesem beeinflusst werden kann, hat eine bestimmte Anzahl von Zuständen. Jede Aktion des Agenten führt zu einem anderen Umweltzustand, für den der Agent als „Reinforcement" eine Belohnung erhält – z. B. einen Wert zwischen 0 und 100. An Hand der Belohnungsintensität kann der Algorithmus selbstständig eine Strategie mit der besten Abfolge von Schritten erlernen, die zum jeweiligen Ziel führt. Genaugenommen könnte man das Reinforcement Learning auch dem unüberwachten maschinellen Lernen zuordnen. Auf Grund der völlig unterschiedlichen Algorithmen und Daten, die vor dem Lernen zur Verfügung stehen müssen, wird allerdings das maschinelle Lernen in drei Teilgebiete gegliedert.

Einsatz im Werkzeug

Grundsätzlich lassen sich die meisten Machine-Learning-Algorithmen auch auf Ressourcen-beschränkten Embedded Systemen einsetzen. Integriert man ein geeignetes Embedded System und die passenden Algorithmen zusammen mit der entsprechenden Sensorik in ein Werkzeug, zum Beispiel in einen Akkuschrauber, entsteht eine intelligente Werkzeugvariante, die per Supervised Learning individuell auf die Merkmale bestimmter Montageaufgaben trainiert werden kann. Im Praxiseinsatz wäre der Akkuschrauber anschließend in der Lage, die Qualität aller Schraubvorgänge an Hand mehrdimensionaler Sensordaten zu bewerten und entsprechende Ausgangsinformationen zu erzeugen. Eine einzelne Schraubverbindung, die mit einem falschen Drehwinkel oder zu geringem Drehmoment bearbeitet wird, würde ebenso wie der Verschleiß des im Schraubkopf steckenden Bits oder ein unzureichend geladener Akku sofort auffallen.

Echtzeit-Bewertung

Realisieren lassen sich solche Qualitäts-sichernden Echtzeit-Bewertungsaufgaben in intelligenten Werkzeugen mit Hilfe von Klassifizierungsalgorithmen, wie zum Beispiel der logistischen Regression, k-Nächste-Nachbarn, Support Vector Machines, Naive Bayes, Entscheidungsbäumen oder auch künstlichen neuronalen Netzwerken. Beim Training der jeweils zum Einsatz kommenden Algorithmen werden einzelne Historiendatensätze zur Modellbildung in unterschiedliche (Qualitäts-) Klassen eingeteilt. Mit anderen Worten: Im einfachsten Fall, der binären Klassifizierung, würde man die periodischen Sensordaten des Akkuschraubers in mehrdimensionale Datenvektoren strukturieren und jeden einzelnen Vektor jeweils einer der beiden Klassen „OK" und „Nicht OK" zuordnen. Daraus lernt der Algorithmus dann ein Modell, dass anschließend auf bisher unbekannte Sensordatenvektoren angewendet werden kann, um diese zu klassifizieren und damit die Qualität der Schraubverbindung zu kennzeichnen.

Die Erfolgsquote bei der Erkennung des fehlerhaften Werkzeugeinsatzes hängt nicht nur vom gewählten Algorithmus, sondern auch von der für das Training zur Verfügung stehenden Sensordatenmenge ab. Da durch den Praxiseinsatz eines intelligenten Akkuschraubers zusätzliche Daten für weitere Trainingsphasen entstehen, lässt sich durch Modell-Updates die Fehlererkennungsquote weiter verbessern. ◄