

Automatische Qualitätskontrolle mittels Maschinellen Lernen und SAP Leonardo

Professor Dr. Frank Herrmann und Simon Büttner MSc.

Innovationszentrum für Produktionslogistik und Fabrikplanung (IPF)

Ostbayerische Technische Hochschule Regensburg

E-Mail: Frank.Herrmann@OTH-Regensburg.de

Schlüsselwörter

Industrie 4.0, SAP Leonardo, SAP S/4HANA, ERP-System, Machine Learning, durchgängig digitalisierter Produktionsprozess bzw. Unternehmensprozess.

Zusammenfassung

In vielen Unternehmen werden von Menschen durch Ansehen von Produkten Produktionsfehler identifiziert. Die übersehenen Produktionsfehler führen zunehmend häufiger zu teuren Kundenreklamationen. Für die Produktion von Fußballen wird in dieser Arbeit diese manuelle Qualitätssicherung analysiert. Als Alternative werden die Fußballen durch einen Roboter fotografiert und durch maschinelles Lernen werden Produktionsfehler auf diesen digitalen Fotos identifiziert. Dieser Prüfprozess wird in SAP Leonardo implementiert und damit wird der bereits in einem SAP System implementierte Produktionsprozess (bzw. Unternehmensprozess) erweitert, wodurch ein durchgängig digitalisierter Gesamtprozess implementiert wird. Dadurch werden signifikant bessere Prüfergebnisse erreicht und die Durchlaufzeit des Prüfprozesses wird substantiell reduziert.

Einleitung

In nahezu allen Unternehmensbereichen schreiten Digitalisierungsprozesse unaufhörlich voran. Hoher Kostendruck, die Erhaltung der globalen Wettbewerbsfähigkeit und die strategische Unternehmensentwicklung zwingen die Unternehmen zur effizienten Generierung, Einsatz und Verteilung von Informationen (Brettel et al., 2014). In diesem Zusammenhang hat auch der Begriff „Machine Learning“ zunehmend an Bedeutung gewonnen. Mit Machine Learning bestrebt man danach, einem Computer deklaratives Wissen, motorische und kognitive Fähigkeiten und neue Fakten durch Beobachtung und Experimentieren beizubringen (Michalski et al., 1983).

Die SAP AG (kurz SAP) konzentriert sich seit Jahren darauf, die digitale Transformation ihrer Kunden zu unterstützen. Um die Hauptaufgabe der Betreuung von Kunden, Lieferanten, Mitarbeitern und Gütern digitalisiert wahrnehmen zu können, setzt SAP auf S/4HANA, der aktuellen Generation ihrer ERP-Anwendung und SAP Leonardo, einem Portfoliebegriff für die Bündelung von Innovationstechnologien als „Digital Innovation System“.

Ebenso arbeitet SAP daran diesen Aspekt der digitalen Transformation in Unternehmensbereichen wie der Produktion umzusetzen, da dieser Unternehmensbereich viel Potenzial birgt. Der Einsatz von Roboterarmen ist dabei

keine neue Errungenschaft mehr. Allerdings bietet er in Kombination mit einer angebrachten Kamera, welche von den Produkten Bilder via Sensoren an die Cloud übermittelt, neues Potenzial für Automatisierung.

Gegenstand dieser Arbeit ist eine auf realen Daten basierende Fallstudie zur Qualitätssicherung bei der Herstellung von Fußballen, deren Verallgemeinerung zunächst vorgestellt wird. Für unseren Anwendungsfall wird der Prozess zur Qualitätssicherung erläutert. Dem schließt sich die Beschreibung und Analyse des Ist-Zustands an. Anschließend wird ein Konzept zur automatische Qualitätskontrolle mit einer Kamera, SAP Leonardo und maschinellem Lernen vorgeschlagen. Seine Umsetzung und die dabei erzielte Verbesserungen zeigen den Erfolg des Vorgehens. Schließlich fassen wir das Vorgehen zusammen und geben einen Ausblick, gerade auch im Hinblick auf andere Unternehmen.

Problemstellung

Viele Schritte laufen in Produktionsstätten noch immer händisch ab, wobei eine hohe Anzahl an Mitarbeitern benötigt wird, um teilweise noch triviale Arbeiten selbst zu erledigen. Dieser Arbeitsablauf hat zunehmend negativen Einfluss auf die Mitarbeiter. Oftmals wird über Demotivation, Monotonie und körperliche Beschwerden geklagt. Diese Arbeitseinstellung hat auch letztendlich Einfluss auf die Produktqualität. Die zu erledigenden Prüfschritte im Qualitätssicherungsprozess sind zwar in den Arbeitsanweisungen fest geregelt, jedoch führt eine subjektive Bewertung durch die unterschiedlichen Prüf-Mitarbeiter zu unterschiedlichen Bewertungsergebnissen.

Aufgrund dieser unterschiedlichen Ergebnisse nimmt die Reklamationsrate ebenfalls von Jahr zu Jahr zu und die Kunden klagen über eine uneinheitliche Qualität. Die dadurch entstehenden Reklamationskosten tragen zu einem signifikant sinkenden Unternehmenserfolg bei.

Um nun diesem negativen Trend ein Ende zu setzen, wird eine Fallstudie aufgesetzt, welche einzelne strategische Ansätze des Qualitätssicherungsprozesses in Betracht zieht und auf Profitabilität prüft. Durch den Einsatz von Machine Learning Algorithmen soll mithilfe von SAP Leonardo auf eine Alternative umgeschwenkt werden, welche verbesserte Ergebnisse verspricht.

Qualitätskontrolle bei der Herstellung von Fußballen

In dieser Fallstudie wird mit dem Verkauf von 12 Mio. Fußballen eines bestimmten Typs gerechnet. Jeder dieser Fußballen wird am Ende des Herstellungsprozesses einer

Qualitätskontrolle unterzogen. Die Kontrolle sieht vor, die Qualität des Balls hinsichtlich Naht, Form, Aufdruck sowie Farbe auf einer Skala von 1 - 10 zu bewerten. Diese Prüfkriterien sind auf S. 6 in Abb. 2 dargestellt.

Fertiggestellte Fußballbälle kommen zusammen mit einem leeren Qualitätsprüfschein (QPS) aus der Produktion auf ein Fließband in die Qualitätssicherungsabteilung. Dort wird nach jedem Kontrollschritt, der von einem der fünf Mitarbeiter (M1 bis M5) ausgeführt wird, der Schein mit Kennzahlen von 1 (ungenügend) bis 10 (ausgezeichnet) für die entsprechende Prüfung beschriftet. Die Prüfungen werden wie folgt durchlaufen:

Falls eine Wertung von unter sechs Punkten festgestellt wurde, wird der fragliche Ball vom Fließband genommen und ihn in eine nahe gelegene Box (Container für Ausschuss) gelegt. Dieser Ball wird später recycelt. Der QPS wird auf dem Band gelassen, damit am Ende des Bandes der Fehler in eine Statistik eintragen werden kann. Nach den vier Prüfungen folgt ein weiterer Arbeitsplatz, der die übrig gebliebenen Prüfscheine auswertet (M5 – Auswertung). Die Wertungen auf den Scheinen entscheiden darüber, ob der Ball erste oder zweite Wahl ist. Für einen Ball mit Qualität „erste Wahl“ darf kein Kriterium mit einer Wertung unter 8 sein. Ein Ball zweiter Wahl darf keine Wertung unter 6 zugeteilt bekommen haben, muss aber mindestens einmal mit über 8 Punkten bewertet worden sein. Bälle der zweiten Wahl werden auf ein an diesem Kontrollpunkt beginnendes zweites Fließband gelegt.

Die Bälle kommen nun in die Verpackung. Der Ausschuss wurde schon zuvor während der Qualitätsprüfungen in die Boxen gelegt.

In der Qualitätssicherung treten zwei Fehlerklassen auf. Zum einen können fehlerfreie Bälle aus Versehen in den Ausschuss gelangen, was in der Statistik als false positive Rate bezeichnet wird. Zum anderen können fehlerhafte Bälle an die Kunden verkauft werden, obwohl deren Qualität nicht einwandfrei ist. Dies kommt der false negative Rate gleich. Die Tabelle 1 veranschaulicht diese Fehlertypen:

	Ist: Fehlerhaft	Ist: Fehlerfrei
Behauptung: Fehlerhaft	True Positive	False Positive
Behauptung: fehlerfrei	False Negative	True Negative

Tab. 1 Konfusionsmatrix Qualitätssicherung

In der Fallstudie liegen die Kosten für einen false positive Treffer bei 50 Euro. Dies spiegelt die Personal- und Materialkosten pro Ball wider. Die Kosten für einen false negative Treffer werden durch die Formel

$$70\text{€} \cdot y + 10^9 \text{€} \cdot \frac{1}{1 + (e^{-30x + 6,5})^y}$$

näherungsweise beschrieben, wobei x die prozentuale Miss-Rate (false negative Rate, z.B. 2%) widerspiegelt und y die Anzahl der false negative Bälle ist. Y kann also aus x gebildet werden, indem $y = x \cdot 12 \text{ Mio. Bälle}$ berechnet

wird. Diese Formel berücksichtigt folgende Besonderheiten: Werden $x \leq 2\%$ aller Bälle aufgrund der Fehler von den Kunden zurückgeschickt, so sind nur geringe Kosten in Höhe von 70 Euro pro Ball zu tragen. Werden aber mehr als 2% der Kunden unzufrieden, führt ein Schneeballeffekt dazu, dass ein Imageschaden langfristige Umsatzeinbußen fordert, welche die Kosten für die zu ersetzenden Bälle deutlich übersteigen. Diese Variable beginnt für $x = 0,02$ zu steigen und führt schnell zu extremen Verlustbeträgen. Die zugehörige Kostenfunktion ist in der folgenden Abbildung 1 aufgezeichnet.

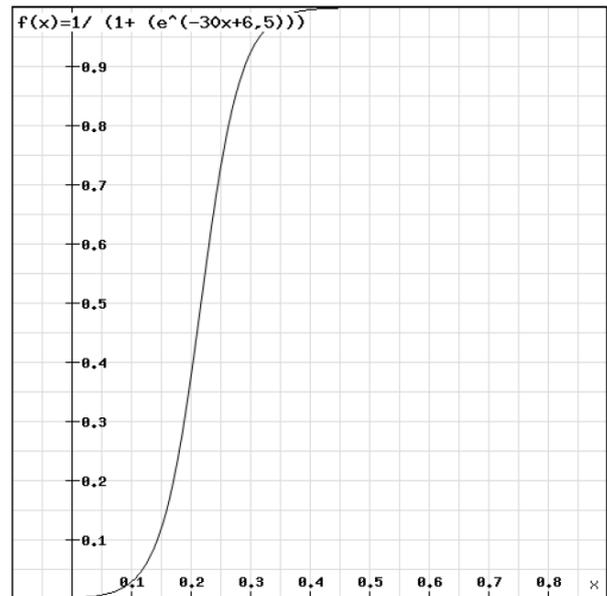


Abb. 1 Graph zur Beschreibung der false negative Kosten

Manuelle Qualitätskontrolle - Ablauf, Dauer und Kosten

Die Bearbeitungszeiten der einzelnen Arbeitsschritte der manuellen Qualitätskontrolle sind folgender Tabelle zu entnehmen:

Prüfung	Dauer	Anmerkung
Nahtprüfung	11 sec	
Formprüfung	10 sec	Mit Hilfsobjekten
Aufdruckprüfung	5 sec	
Farbqualitätsprüfung	5 sec	
Bewertung	5 sec	
Fließbandbewegung	9 sec	
GESAMT	45 sec	

Tab. 2 Dauer manuelle Qualitätssicherung

Es werden 12 Mio. Bälle (24 Mio. Stück $\cdot 0,5$) produziert. Dies bedeutet, dass insgesamt 150.000 Stunden an den Bällen kontrolliert wird ((12 Mio. Stück $\cdot 45\text{sec}/\text{Ball}$) / 3 600). Es kann in einem Jahr an ungefähr 250 Tagen gearbeitet werden, wobei in 3 Schichten gearbeitet wird. Ein Mitarbeiter arbeitet 7 Stunden am Tag in der Qualitätskontrolle. Dies bedeutet, dass ein Mitarbeiter knapp 2 100 Stunden im Jahr arbeiten kann. Für die Qualitätskontrolle am Fließband werden also knapp 72 Mitarbeiter in Vollzeit angestellt (150 000 Std / 2 100 Std).

Da die Bewertung des QPS fünf Sekunden dauert, kann theoretisch ein Ball alle fünf Sekunden aus der Qualitätssicherung kommen. Dies erfordert, dass jeweils zwei Mitarbeiter für die länger andauernden Prüfungen Naht und Form bereitstehen müssten, damit diese Taktung beständig bleibt. Insgesamt werden 12 Mio. Bälle bewertet.

Die Kosten für einen sehr geringen Imageschaden liegen bei kalkulierten 3,2 Mio. Euro. Insgesamt können also Mehrkosten in Höhe von 48,2 Mio. Euro erwartet werden.

Um die Funktion der false negative Formel unter Beweis zu stellen, sei folgender Hinweis angebracht. Wenn jeder zehnte Ball beim Endkunden offensichtliche Mängel

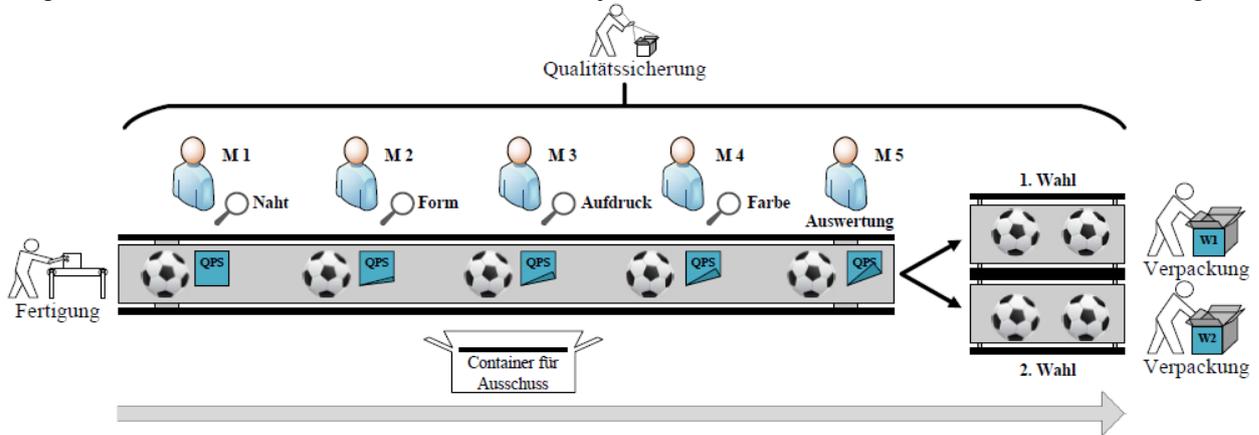


Abb. 2 Manuelle Qualitätssicherung

Somit benötigt die Qualitätssicherung 12 Mio. · 5 Sekunden = 60 Mio. Sekunden Zeit. Dies lässt sich auf 16 667 benötigte Stunden, an denen ein Band laufen muss, umrechnen. Ein Band steht dabei jährlich 5 250 Stunden (21 Std. · 250 Tage) zur Verfügung. Es wird nun allerdings mit einer Maschinenlaufzeit von 5 000 Stunden pro Jahr gerechnet. Dieser Wert ergibt sich aus der branchenüblichen Durchschnittslaufzeit dieses speziellen Bandes und berücksichtigt Ausfälle, Wartung und sonstige Stillstände. Dies wiederum bedeutet, dass mindestens vier parallele Linien in der Qualitätssicherung (5 000 Stunden · 4 > 16 666 Stunden) laufen müssen, um den Aufwand von 12 Mio. zu kontrollierenden Bällen in einem Geschäftsjahr stemmen zu können. Der ungefähre Kostenaufwand pro Stunde für die Instandhaltung der Qualitätskontrolle wird auf 8 Euro geschätzt. Dabei sind beispielsweise die Lohnkosten, die Kosten für Arbeitsbekleidung, die Räumlichkeiten und die Versicherungen enthalten. Daraus entstehen Gesamtkosten in Höhe von 1,2 Mio. Euro (8€/Std · 150 000 Std). Man kann davon ausgehen, dass ein Mitarbeiter in ca. 25 Prüfungen einen ordentlichen Ball versehentlich entfernt. Die vereinfachte false positive Rate liegt also bei 4%. Weiterhin geht ein Ball mit nur einem Qualitätsmangel zu 3% unerkannt in den Versand. Hat dieser Ball jedoch Mängel bezüglich mehrerer Prüfkriterien, sinkt die Wahrscheinlichkeit, dass kein Fehler erkannt wird und der Ball somit in den Handel gelangt. Dies führt zu einer vereinfachten false negative Rate von 2,5%. Diese Raten haben Auswirkungen auf das Kostenmodell. Wenn 4% aller fehlerfreien Bälle aussortiert werden, entstehen Mehrkosten in Höhe von 50 .Euro · 4% · 12 Mio. Bälle = 24 Mio. Euro. Wenn 2,5% der ausgelieferten Bälle zurückgehen, so müssen zusätzliche Kosten von

$$\frac{70\text{€} \cdot y + 10^9 \text{€} \cdot \frac{1}{1 + (e^{-30x + 6,5})}}{y} = 24,2 \text{ Mio €}$$

getragen werden. Hierbei berechnen sich die Rücksendungen und der Ersatz auf insgesamt 21 Mio. Euro.

aufweist und es somit zu einem Schneeballeffekt an Rücksendungen und einem mittleren Imageschaden kommt, so errechnen sich Mehrkosten in Höhe von 29,3 Mio. Euro.

Automatische Qualitätskontrolle mit SAP Leonardo und maschinellem Lernen – Konzept

Prozess

Statt einer manuellen Fehlerprüfung wird nun ein Roboterarm verwendet, an welchem eine Kamera angebracht ist. Diese Vorrichtung schießt pro Ball mehrere Bilder und schickt diese als Binärdaten via der Image Classification API an SAP Leonardo, welches dann die Bilder mittels Machine Learning analysiert. Die Bilder sowie die Machine Learning Analysen werden mittels einer SAP Leonardo Applikation für Endbenutzer sichtbar. Dabei werden alle Kriterien geprüft, indem jedes Bild klassifiziert wird und am Ende eine Entscheidung über die Qualität des Balls getroffen wird. Die Applikation bildet folgende Funktionalitäten im Dashboard ab. Dahinter stehen in Klammern die verwendeten Technologien, die durch den SAP Leonardo Engagement Prozess angeboten wurden:

- Analysedaten aus der Variabilitätsmodellierung zur Klassifizierung der Waben (Analytics, Big Data, ML).
- Zahlen zur Genauigkeit der Klassifikation (Analytics).
- Anzahl der verarbeiteten Bälle in einer Stunde sowie weitere Performance-Daten (Analytics, IoT).
- Benachrichtigungsoptionen bei Ausfall des Roboter-Arms oder anderer abhängiger Komponenten sowie Ausfallquoten (Analytics, IoT).
- Kosteneinsparungen (Analytics).
- Energieverbrauch (IoT).
- Schnittstelle zur Verbreitung des Trainingsmodells auf den Roboterarm (IoT, ML).

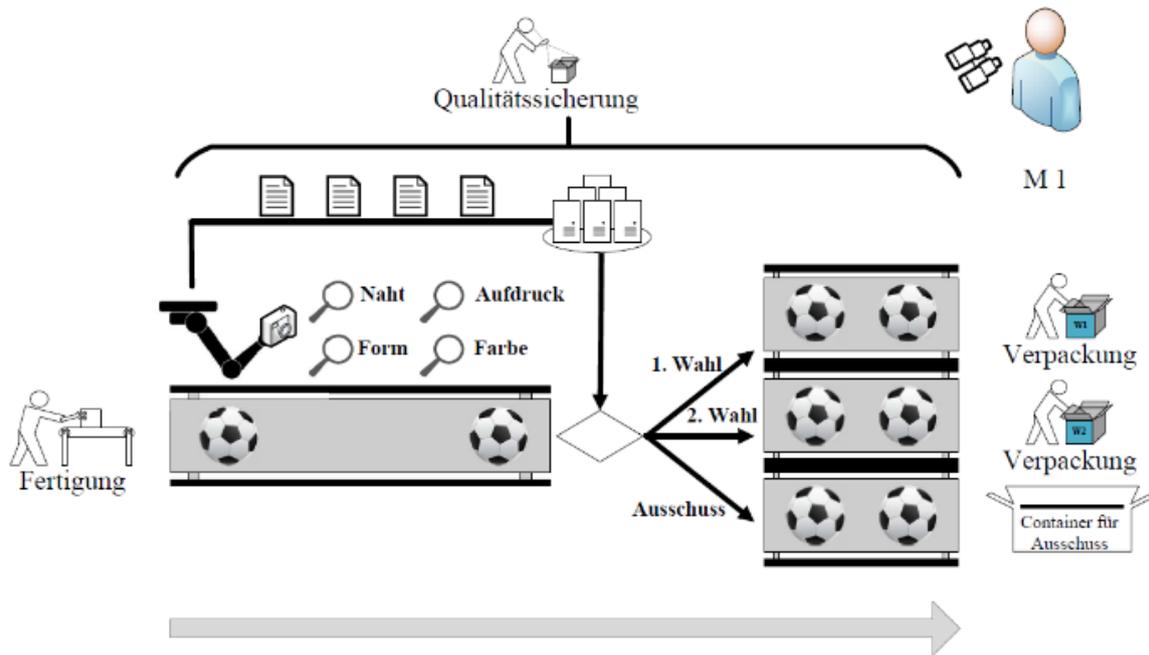


Abb. 3 Qualitätssicherung mit Roboterarm & SAP Leonardo

Der Prozess läuft im Detail – wie in Abb. 3 zu sehen ist – wie folgt ab: Die Produktionsabteilung legt die Bälle auf ein Förderband in unmittelbarer Nähe zur Qualitätssicherung. Das Band stoppt an dem Punkt (linker Ball), an dem der Roboterarm befestigt ist. Der Roboterarm schießt in sehr kurzer Zeit mit einer integrierten Kamera hochauflösende Bilder des Balles. Der Ball wird mit dem Fließband weitergetragen. Dank eines Time-Tracking Systems, das im Hintergrund läuft, kann jede Bilderreihe genau einem Ball zugeordnet werden. Das Fließband muss also nicht stoppen, bis die Analyse ein Ergebnis hervorbringt. Bis zum Ende des Fließbands hat das Softwaresystem Zeit, die Bilder zu analysieren, um eine Entscheidung zu treffen, ob der Ball in Ordnung ist oder in den Ausschuss gelangt. Der Roboterarm muss also die Bilder via WLAN an einen gut performanten Server schicken, auf dem die Bilder via Machine Learning und Bildverarbeitungsalgorithmen analysiert werden können. Das Machine Learning Modell ist in der Lage, die Naht, die Form, den Aufdruck sowie die Farbqualität synchron zu prüfen. Auf die genaue Funktionsweise der Machine Learning Algorithmen wird später im Rahmen der Fallstudie eingegangen. Es werden die gleichen Ratings verwendet, wie vor der Einführung von SAP Leonardo. Wenn die Machine Learning Unit durchlaufen ist, wird dank des Time-Tracking Systems der Ball eindeutig in „in Ordnung“ und „Ausschuss“ klassifiziert. Diese Information kann dann am Ende des Fließbands genutzt werden, um den Ball an den zutreffenden Prozess zu schicken. Zudem hat das IT-Team eine kleinere Idee in die Tat umgesetzt. Zur weiteren Akzeptanzschaffung der Neuerung wurde ein Monitor in der Nähe des Roboterarms aufgestellt, der die Klassifizierung mittels roter und grüner Ampeln symbolisch visualisiert.

Konzept vom maschinellem Lernen

Am Beispiel der Oberflächenprüfung wird nun die Funktionsweise des ML Algorithmus beschrieben. Bei der

Oberflächenprüfung scannt die Kamera jede einzelne der 32 Waben ein und übermittelt das Bild via der Image Classification API an das SAP Leonardo System.

Diese Daten werden in ein Gitternetz aus 418 (22 · 19) Pixel übertragen, wobei jeder Pixel einen Farbwert zwischen 0 (schwarz) und 1 (weiß) hat. Somit lässt sich der Aufdruck jeder Wabe zahlenmäßig genau erfassen. Diese 418 Farbwerte werden nun an die Tabelle 1 der in SAP Leonardo integrierten Datenbank übertragen. Nach der Aufbereitung werden die Daten mit den im Koordinatensystem hinterlegten Daten abgeglichen. Jede dieser 32 Waben soll nun im Optimalfall eine korrekte Zuordnung erhalten. Falls nun aber die Wabe mit Verunreinigungen bzw. mit Oberflächenfehlern behaftet ist, wird es zu keiner Übereinstimmung kommen. Das System wird alarmiert und der Ball wird als qualitativ minderwertig aussortiert.

Mittels dem kNN-Modell und der von (Keyers, 2007) beschriebenen Variabilitätsmodellierung wird nun dieses Bild analysiert und zum Schluss festgestellt, ob sich alles an korrekter Position befindet und keine größeren Druckfehler vorhanden sind.

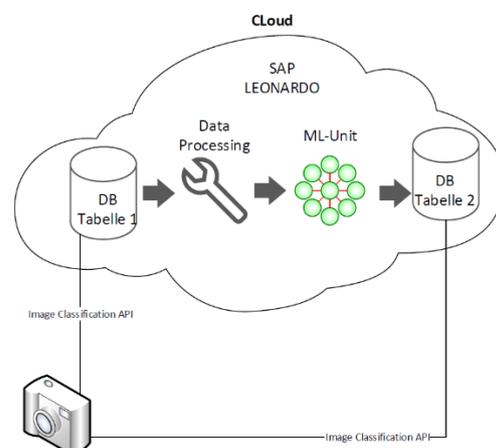


Abb. 4 IT Architektur SAP Leonardo

Die von SAP Leonardo zur Verfügung gestellte IT Architektur setzt sich dabei folgendermaßen zusammen – diese sind in Abbildung 4 visualisiert.

Zu Beginn werden die Rohdaten an Tabelle 1 einer Datenbank (DB) übermittelt. In dieser werden alle von der Kamera übermittelten Daten zusammen mit einem eindeutigen Key gespeichert. Dies wird benötigt, um einen Zugriff auf alle Original-Daten zu ermöglichen.

Von Tabelle 1 aus werden alle Daten automatisch an die Data-Pre-Processing Unit weitergeleitet. Hier werden alle Roh-Datensätze mit weiteren Daten wie z.B. Time stamps versehen und zusätzlich noch für die ML-Unit vorselektiert und normiert. Die Normierung ist wichtig, um mögliche Ausreißer-Werte zu eliminieren, wodurch das Ergebnis nicht zu verfälscht wird. Außerdem werden nicht benötigte Datensätze gelöscht, um die Gesamtperformance des Systems zu steigern.

Die fertig aufbereiteten Daten werden nun an die ML-Unit als Input für das ML Modell übermittelt. Die genaue Funktionsweise dieses Modells wird im darauffolgenden Abschnitt näher spezifiziert.

Das Ergebnis der ML-Unit wird abschließend in einer weiteren Tabelle der Datenbank gespeichert. In Tabelle 2 lassen sich alle Ergebnisse zur Klassifizierung aus dem vorhergehenden Schritt auslesen, evaluieren und visualisieren. Letztendlich wird das Ergebnis der Waben-Klassifizierung in Real-Time zurück an die Terminals des Qualitätsprüfungs-Bandes übermittelt.

SAP Leonardo stellt dabei sicher, dass alle Daten des Kamera-Arms korrekt empfangen werden, zwischen den einzelnen Units gestreamt und letztlich in Real-Time analysiert und an die Qualitätssicherung rückgemeldet werden. SAP stellt somit eine kontinuierliche Weiterverarbeitung bzw. Weiterleitung der Daten zu jedem Zeitpunkt sicher.

In den folgenden Abschnitten wird nun erklärt, wie die Klassifizierung in der ML-Unit abläuft.

Vertiefung: die Nächste-Nachbar-Regel (kNN)
Die nächstgelegene Nachbarn-Regel (kNN) ist eine der ältesten und einfachsten Methoden zur Musterklassifizierung. Dennoch führt sie häufig zu wettbewerbsfähigen Ergebnissen und in bestimmten Bereichen hat sie in Kombination mit Vorwissen den Stand der Technik erheblich verbessert. Die kNN-Regel klassifiziert jedes nicht gekennzeichnete Beispiel anhand der Mehrheitsbewertung unter seinen k-nächsten Nachbarn im Trainingssatz. Seine Leistung hängt daher entscheidend von der Entfernungsmetrik ab, die zur Identifizierung der nächsten Nachbarn verwendet wird. In Ermangelung von Vorwissen verwenden die meisten kNN-Klassifizierer einfache euklidische Distanzen, um die Unähnlichkeiten zwischen den als Vektoreingaben dargestellten Beispielen zu messen (Weinberger & Saul, 2009). Zusammen mit des in Kapitel „Variabilitätsmodellierung“ beschriebenen Verfahren soll die kNN konkret in Bezug auf die Fallstudie beschrieben werden.

Vertiefung: Variabilitätsmodellierung

Es ist eine große Herausforderung, einem Computer das Verstehen von Bildern beizubringen. Durch Einbeziehen typischer Veränderungen in Bildern ist man jedoch imstande, die Erkennung bzw. die Zuordnung von Bildern zu

verbessern. Hierzu wird ein Verfahren beschrieben, welches die Variabilität in der Klassifikation von Bildern untersucht.

Ziel der Klassifikation soll sein, aus vorhandenen Daten eine möglichst optimale Entscheidung abzuleiten. Diese Entscheidungen werden in einer Zuordnung zu einer Klasse $k \in \{1, \dots, K\}$ beschrieben. Optimalität wird erreicht, wenn die Fehlerrate bzw. die falschen Klassenzuordnungen minimiert werden. Zurückgegriffen wird dabei auf Trainings- und unabhängigen Testdaten. Weiterhin wird das Wissen eingesetzt, dass bestimmte Variationen in den Bildern deren Klassenzugehörigkeit nicht verändert. Zur Behandlung der Variabilität wird dabei auf invariante Distanzfunktionen – die Nächste-Nachbar-Regel (kNN) – gesetzt (Keyers, 2007).

In Bezug auf die Fallstudie der Waben kann die Variabilität mit der in Kapitel „Grundlagen“ beschriebenen Qualitätsbewertungen verglichen werden. Bis dato wurden all jene Waben mit Wertung > 8 als erste Wahl eingestuft. Da dadurch jede Wabe einen gewissen Qualitäts-Spielraum hat, innerhalb dessen die Qualität als erste Wahl eingestuft werden kann, muss dies im Rahmen des Machine Learning Algorithmus kNN berücksichtigt werden.

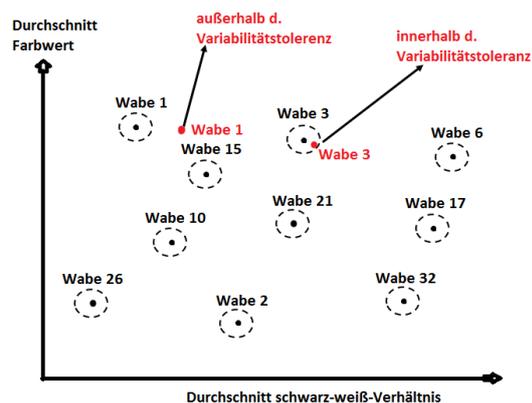


Abb. 5 Visualisierung der Variabilität

Automatische Qualitätskontrolle mit SAP Leonardo und maschinellem Lernen – Umsetzung

Ziel von SAP Leonardo ist es, dass jede von der Kamera aufgezeichnete Wabe vom ML-Algorithmus auf Basis des zuvor erläuterten Verfahrens zu klassifizieren. In diesem Anwendungsfall werden die Entscheidungen in die Klassen $k \in \{1, \dots, 32, \text{Fehler}\}$ vorgenommen. Jede einzelne Wabe fungiert dabei als eigene Klasse. Diese 33 Klassen stehen dabei schon im Vorfeld fest, auf Basis deren das Modell nun mit Trainingsdaten gelernt wird. Hierzu werden die Daten von insgesamt 100 000 Waben mit sehr guter Qualität herangezogen. Diese Durchschnittswerte, basierend auf dem jeweiligen Farbwert und dem schwarz-weiß-Verhältnis, werden nun zur besseren Visualisierung etwas vereinfacht in einem Koordinatensystem dargestellt.

Die grundlegende Voraussetzung hierbei ist, dass jede Wabe unterschiedliche Farb- und Schwarz-Weiß-Werte

hat. Somit kann jeder Wabe im Koordinatensystem ein eigener Bereich zugeordnet werden, ohne sich mit anderen zu überschneiden.

Die schwarzen Punkte repräsentieren hierbei die einzelnen Waben (1,...,32), welche die Trainingsdaten repräsentieren. Der gestrichelte Kreis um die Punkte stellt die Variabilität dar, welche sich aus dem erlaubten maximalen Qualitäts-Spielraum, im Rahmen des kNN ermittelt, ergibt.

Die roten Punkte sind nun neue bzw. unbekannte Testdaten, also eine neu abfotografierte Wabe, welche es jetzt zu klassifizieren gilt. Diese Test-Wabe wird nun entsprechend ihrer Farbwerte und des schwarz-weiß-Verhältnisses an der entsprechenden Stelle im Koordinatensystem platziert. Mittels der euklidischen Distanz wird nun der nächste Nachbar (k=1) ermittelt. Am Beispiel von Wabe 3 (rot) aus Abb. 5 wäre dies ebenfalls Wabe 3 (schwarz). Da der rote Punkt von Wabe 3 innerhalb der gestrichelten Linie liegt und die Distanz zu seinem Nachbarn sehr gering ist, wäre eine entsprechende Klassifizierung erfolgreich. Ein Beispiel eines solchen Falls wären die 32 Waben eines Fußballs, deren Qualität der Waben 24-mal mit 9 und 8-mal mit 10 bewertet wurde. Somit hätte der rote Punkt nur eine sehr kurze Distanz zu seinem schwarzen Trainingspunkt und würde als qualitativ hochwertig eingestuft werden.

Am Beispiel von Wabe 1 (aus Abb. 5), würde man er-

die restlichen 27 mit 9 bewertet worden wären. Dadurch wäre die Qualität einiger Waben ungenügend und der zugehörige Fußball müsste dementsprechend aussortiert werden.

Abb. 6 zeigt etwas vereinfacht den genauen Klassifizierungs-Prozess von Wabe Nr. 24 von der Original-Fotografie bis zu seiner endgültigen digitalen Transformation in einen Feature-Vektor. Weiterhin soll sie dabei den Unterschied zwischen einer Wabe mit guter Qualität (oben) und einer Wabe mit schlechter Qualität (unten) veranschaulichen.

Ein Feature-Vektor ist dabei ein eindimensionales Array bestehend aus mehreren Nullen und Einsen und stellt eine maschinenlesbare Verschlüsselung der Positions- und Farbdaten jeder einzelnen Wabe dar. Dieser Vektor bildet dabei den Test-Parameter ab. Auf der rechten Seite der Abbildung ist der ebenfalls ein Feature-Vektor zu sehen, welcher die qualitativ sehr guten Trainings-Waben beinhaltet. Mittels des kNN-Algorithmus wird nun der Feature-Vektor der Test-Wabe mit dem Feature-Vektor der Trainings-Waben verglichen. Zum einen wird als Ergebnis ausgegeben, ob die zu testende Wabe

- der Trainings-Wabe am nächsten ist und
- nahe genug an der Trainings-Wabe liegt.

Sind beide Punkte erfüllt – wie bei der oberen Wabe

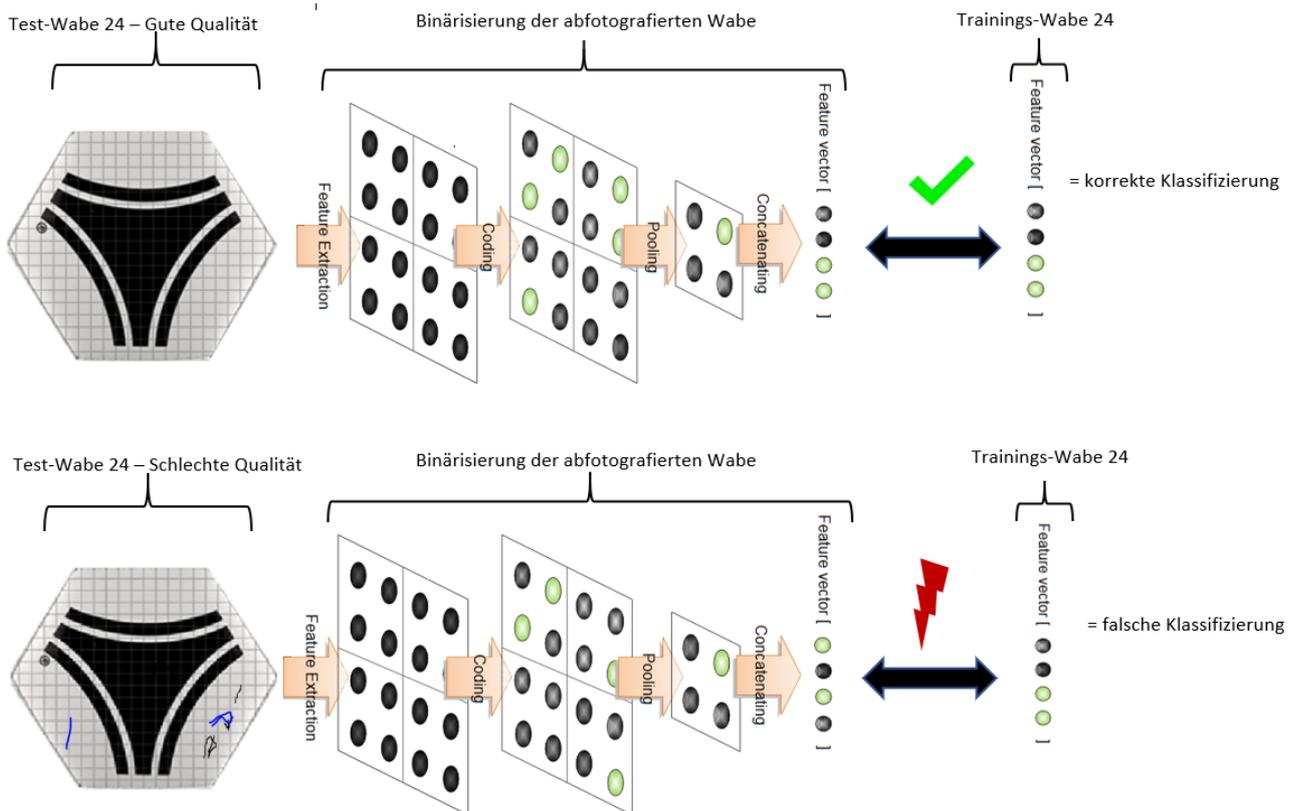


Abb. 6 Binärisierung einer Wabe

kennen, dass auch hier Wabe 1 (schwarz) tendenziell der nächste Nachbar wäre. Da nun allerdings der rote Punkt eine viel zu große Entfernung zu seinem schwarzen Pendant aufweist, wird es zu keiner erfolgreichen Klassifizierung kommen. Dies könnte beispielsweise der Fall sein, wenn 5 der 32 Waben mit einem Qualitäts-Wert < 7 und

aus Abb. 6 – so kommt es zu einer korrekten Klassifizierung und besteht somit den Qualitätstest.

Sind jedoch Beschädigungen auf der Wabe vorhanden, so ist einer der beiden Punkte nicht erfüllt und es kommt

dadurch – wie die untere Wabe in Abb. 6 - zu keiner erfolgreichen Klassifizierung. Die Wabe besteht den Qualitätstest nicht.

Dies weist darauf hin, dass das eben angewandte Verfahren das Erlernen relevanter Feature-Vektoren für die Durchführung einer genaueren Vorhersage, wie bereits von (Essid, Laga & Samir, 2018) beschrieben, evaluiert.

(Keyers, 2007) hat bereits eruiert, dass Klassifizierungen von Bildern imstande sind, eine nur sehr geringe Fehlerrate aufweisen zu können. So konnten von ihm Fehleraten von nur 0,52% statuiert werden.

Die folgenden Zahlen zeigen auf, wieviel Zeit die Qualitätskontrolle eines Balls (32 Waben) nach der Einführung von SAP Leonardo in Anspruch nimmt und welche Schritte der Qualitätsprüfung einen zeitlichen Einfluss darauf haben.

Prüfung	Dauer
Bewegung Roboterarm	9 sec
Klassifizierung d. Bilder	/
Fließbandbewegung	6 sec
GESAMT	15 sec

Tab. 3 Dauer Qualitätssicherung mit SAP Leonardo

Die Klassifizierung der Waben geschieht direkt nach der Aufnahme der Bilder während sich der Roboterarm noch bewegt. Bis der Ball also durch die Fließbandbewegung bei dem Bildschirm, welcher die Klassifizierungsergebnisse anzeigt, angelangt ist, steht schon fest, in welche Kategorie er eingeordnet werden kann. Da die Klassifizierung parallel abläuft, ist die Dauer dieser nicht relevant für die Zeit, die pro Ball benötigt wird. Bezüglich der zusätzlichen Kosten, die durch die Einführung von SAP Leonardo anfallen, wird mit folgenden Kosten kalkuliert:

Wie bereits bei der Qualitätskontrolle vor der Einführung von SAP Leonardo wird auch hier mit einer produzierten Stückzahl von 12 Mio. Bällen gerechnet. Die Qualitätskontrolle dieser dauert nun nur noch (12 Mio. Stück · 15sek/Ball) / 3600 = 50 000 Stunden. Da der Prozess der Prüfung der einzelnen Qualitätsmerkmale nun nicht mehr hintereinander abläuft, sondern alle Kriterien auf einmal geprüft werden, werden mehrere solcher Roboterarme benötigt. Man geht davon aus, dass jede dieser Anlagen ein ganzes Jahr über durchlaufen kann, also 8.760 Std pro Jahr in Betrieb ist. Es werden somit 50 000Std / 8 760 Std = 5,7 - also insgesamt sechs Roboterarme - benötigt. Die Auslastung der Arme beträgt nun weniger als 100. Während dieser Stunden ist jeweils ein Mitarbeiter für zwei Anlagen zur Kontrolle der Prozesse anwesend. Somit sind für diesen Prozess zu jeder Zeit drei Mitarbeiter anwesend. Um faire Arbeits- und Urlaubszeiten zu gewährleisten, werden hierfür 12 Mitarbeiter eingestellt. Für die Instandhaltung aller Anlagen werden zwei Mitarbeiter, einer für die Software, der andere für die Hardware, mit 288 Stunden pro Jahr beauftragt. Vor jeder Saison müssen zwei Mitarbeiter das Datenmodell entwickeln und trainieren. Hierfür werden 160 Stunden angesetzt. Insgesamt werden also circa 16 Mitarbeiter benötigt, welche jedoch alle nicht voll beschäftigt werden. Pro Jahr muss somit für die Qualitätskontrolle dieses Balles für 8.760Std · 3 + 48 Std + 160 Std = 26 488 Stunden aufgekomen werden. Ein Mitarbeiter verdient

nun deutlich mehr, da er entsprechend fortgebildet wurde und höhere Tätigkeiten ausführen muss. Es ist mit einem Kostenaufwand von 15 Euro pro Stunde auf Unternehmensebene zu rechnen. Im ersten Jahr nach der Einführung von SAP Leonardo fielen 200.000 Euro an zusätzlichen Kosten an.

Die jährlichen Kosten ohne Personalaufwand betragen 2.000 Euro + 500 Euro + 3.500 Euro = 6.000 Euro. Somit betragen die Gesamtkosten im ersten Jahr 200.000 Euro + 6.000 Euro + 26.488 Std · 15 Euro/Std = 603.320 Euro. Nachdem die einmaligen Kostenpunkte wegfallen, beträgt der jährliche Aufwand für die Qualitätskontrolle im zweiten Jahr nun 403.320 Euro. Die Personalkosten pro Jahr belaufen sich hierbei auf 397.320 Euro. Um die Kosten besser mit denen des vorherigen Prozesses der Qualitätskontrolle zu vergleichen, ist anzumerken, dass sämtliche zusätzlichen Kosten, wie beispielsweise Betriebskosten, bereits im Stundenlohn integriert sind. Es kann daher davon abgesehen werden, nur die Personalkosten miteinander zu vergleichen. Vielmehr sollten für einen fairen Kostenvergleich die Gesamtkosten des SAP Leonardo Systems, also 403 320 Euro jährlich nach der Einführung, in Betracht gezogen werden.

Für die false positive Rate wird nun die von (Keyers, 2007) ermittelte Fehlerrate von 0,52% herangezogen. In der manuellen Qualitätskontrolle lag die false negative Rate bei 2,5% und die false positive Rate bei 4%. Die false negative Rate liegt unter SAP Leonardo nur noch bei 0,05%, da es unwahrscheinlicher ist, dass ein defekter Ball die Qualitätskontrolle besteht, insbesondere wenn mehr als ein Qualitätskriterium nicht erfüllt ist. Der Algorithmus arbeitet somit wesentlich genauer als das menschliche Auge. Es ist zu berücksichtigen, dass diese Fehlerraten stark davon abhängen, wie gut das Variabilitätsmodell trainiert wird. Es wird großer Wert darauf gelegt, dass dieser Prozess besonders gründlich durchgeführt wird, um die Fehlerraten möglichst gering zu halten.

Die Auswirkungen dieser Raten auf das Kostenmodell lassen sich wie folgt beschreiben: 0,52% aller fehlerfreien Bälle werden trotz ausgezeichneter Qualität aussortiert. Der Schaden, der hierbei entsteht, beläuft sich nur noch auf 50 Euro · 0,52% · 12Mio. Bälle = 3 120 000 Euro. Es werden immer noch 0,05% der ausgelieferten Bälle zurückgesendet. Hieraus entstehen zusätzliche Kosten von

$$70 \cdot 0.0005 + 12 \text{ Mio.} + 10^9 \text{ Euro} \cdot \frac{1}{1+(e^{-30 \cdot 0,0005 + 6,5})}$$

= 1,94 Mio. Euro,

da zusätzlich zu den Kosten eines false positive Fehlers unter anderem Rücksendekosten und Imageschäden getragen werden müssen. Insgesamt ergeben sich daraus Mehrkosten von circa 5,06 Mio. Euro.

Automatische Qualitätskontrolle mit SAP Leonardo und maschinellem Lernen – Erzielte Verbesserungen

Zum Vergleich der manuellen mit der automatischen Qualitätskontrolle werden die Dauer der Qualitätskontrolle eines Balles, Anzahl der benötigten Mitarbeiter, Dauer der Mitarbeiterarbeit, jährliche Prozesskosten, Kosten aus false positive Fehlern und Kosten aus false negative Fehlern gegenübergestellt.

Alle Kennzahlen werden durch die automatische Qualitätskontrolle verbessert; die einzelnen Werte befinden sich in Tabelle 4. So konnte die Dauer der Qualitätskontrolle eines Fußballs durch SAP Leonardo um circa 62.5% gesenkt werden. Die Anzahl der benötigten Mitarbeiter für den Prozess der Qualitätskontrolle konnte ebenfalls deutlich gesenkt werden, konkret ausgehend von der bereits eingeführten Methode um circa 78%. Daraus resultierend sank auch die Dauer der benötigten Mitarbeiterarbeit um 83%. Die jährlichen Prozesskosten konnten um 66% verringert werden. Bei den Kosten für alle false positive Fehler liegt eine beträchtliche Einsparung von 87% vor, welche auf die Erfahrungen der Entwickler des Variabilitäts-Modells zurückzuführen ist. Schließlich liegt bei den Kosten für alle false negative Fehler eine Verringerung um 92% vor. Das größte Verbesserungspotenzial liegt bei den Fehlerkosten – in beiden Fällen über 85%. Diesen Einsparungen stehen erhöhte Einführungskosten von 603320 Euro im ersten Jahr gegenüber. Deswegen lohnt sich eine Einführung von SAP Leonardo. Ein weiterer Vorteil besteht darin, dass die Architektur rund um SAP Leonardo und des Roboterarms für andere bzw. ähnliche Anwendungsfälle verwendet werden kann.

	Manuell	Mit SAP Leonardo
Dauer Qualitätssicherung pro Ball in Sek	45	15
Anzahl Mitarbeiter	72	16
Dauer in Stunden	150 000	26 488
Jährliche Prozesskosten	1.2 Mio	403 320
Kosten false positive	24 Mio	3,12 Mio
Kosten false negative	24.2 Mio	1.94 Mio

Tab. 4 Gegenüberstellung Kennzahlen

Zusammenfassung

Diese auf realen Daten basierende Fallstudie zur Qualitätssicherung demonstriert eine vollautomatische Qualitätskontrolle mit SAP Leonard. Aufgrund den in der Literatur nachgewiesenen Ergebnissen durch maschinelles Lernen dürften sich substantiell geringere Fehlerraten realisieren lassen. Die dann erreichbaren Prozessbeschleunigungen um $\frac{200}{3}$ % und Kostenreduktionen auf einen kleinen Bruchteil sind so gewaltig, dass in naher Zukunft mit tatsächlichen Projekten gerechnet werden kann. Da Bilderkennung beim Kommissionieren von Montagebauteilen sehr wirkungsvoll sein dürfte, mögen viele Anwendungen in Industrie 4.0 sich durch diese Fallstudie inspirieren lassen.

Literaturverzeichnis

- Buxmann, Peter; Schmidt, Holger (Hg.) (2019): Künstliche Intelligenz. Mit Algorithmen zum wirtschaftlichen Erfolg. Berlin, Heidelberg: Springer Berlin Heidelberg. Online verfügbar unter <https://doi.org/10.1007/978-3-662-57568-0>.
- Essid, O.; Laga, H.; Samir, C. (2018): Automatic detection and classification of manufacturing defects in metal boxes using deep neural networks. In: PloS one. DOI: 10.1371/journal.pone.0203192
- Gurney, Kevin N. (1997): An introduction to neural networks. London: UCL Press. Online verfügbar unter <http://gbv.ebib.com/patron/FullRecord.aspx?p=182103>.
- Keuper, Frank (Hg.) (2013): Digitalisierung und Innovation. Planung, Entstehung, Entwicklungsperspektiven. Wiesbaden, s.l.: Bearingpoint. Online verfügbar unter <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=580534>.
- Keyers, Daniel (2007): Variabilitätsmodellierung für die Bilderkennung. In: Dorothea Wagner (Hg.): Ausgewählte Informatikdissertationen 2006. Bonn: Ges. für Informatik (Lecture notes in informatics, D-7).
- Malte Brettel; Niklas Friederichsen; Michael Keller; Marius Rosenberg (2014): How Virtualization, Decentralization And Network Building Change The Manufacturing Landscape. An Industry 4.0 Perspective.
- Michalski, Ryszard S.; Carbonell, Jaime G.; Mitchell, Tom M. (Hg.) (1983): Machine Learning. An Artificial Intelligence Approach. Berlin, Heidelberg: Springer (Symbolic Computation). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-662-12405-5>.
- Traeger, M.; Eberhart, A.; Geldner, G.; Morin, A. M.; Putzke, C.; Wulf, H.; Eberhart, L. H. J. (2003): Künstliche neuronale Netze. In: Der Anaesthetist 52 (11), S. 1055–1061. DOI: 10.1007/s00101-003-0576-x.
- Weinberger, Kilian; Saul, Lawrence K. (2009). Distance Metric Learning for Large Margin Nearest Neighbor Classification. *J. Mach. Learn. Res.* 10 (June 2009), 207-244.