

Die Deep Qualicision KI verbindet die KI-Entscheidungsmaschine Qualicision mit maschinellem Lernen. Dieses Lösungskonzept erlernt das Einstellen von Parametern von Optimierungsalgorithmen auf effiziente Weise, so dass Entscheidungen, die auf Daten und Optimierungsergebnissen beruhen, sich automatisch selbst justieren. Es steht für alle PSI-Softwaretools, die mit Qualicision ausgestattet sind, zur Verfügung und trägt KI in die Breite der PSI-Lösungen.

Das Herzstück von Deep Qualicision ist ein maschinelles Lernverfahren, das auf der selbsttätigen Erkennung von KPI-Zielkonflikten in den Prozessdaten von Geschäftsprozessen mittels Erweiterter Fuzzy-Logik beruht. Die Zielkonfliktanalyse hilft, die Prozessdaten so zu ordnen, dass der Deep-Qualicision-Algorithmus selbstständig erkennen kann, in welchen Situationen wie vorzugehen ist, damit die Geschäftsprozesse optimal geplant und gesteuert werden können.

Faszinierenderweise kann dabei direkt auf bereits etablierte Qualicision-

Optimierungen zurückgegriffen werden. Werden nämlich Geschäftsprozesse durch Qualicision-Algorithmen optimiert, kann der für KI-Lösungen zwingend benötigte Vorgang des Labelns von Prozessdaten mit Hilfe der etablierten kennzahlenorientierten KPI-Optimierung qualitativ erfolgen. Und zwar durch Qualicision-Algorithmen, also durch die Optimierung selbst.

Durch Menschenhand – Stichwort millionenfach ins Netz gestellte Katzenbilder – gelabelte Daten, also die manuelle Zuordnung, ob die vorliegenden Daten zu guten oder zu

schlechten KPI-Ergebnissen im vorliegenden Prozess geführt haben, werden nicht länger benötigt. Hierdurch wird der bisherige Flaschenhals der Datenaufbereitung für KI-Verfahren beseitigt.

### Qualitatives Labeln als selbsttätige KPI-Labeling-Maschine

Auf diese Weise kann jede bereits geschaffene Qualicision-Lösung als KPI-Labeling-Maschine aufgefasst und eingesetzt sowie zur Implementierung von effizienten KI-Lernstrategien genutzt werden. Das qualitative Labeln schafft neue Perspektiven für die Anwendung von Deep Learning in Geschäftsprozessen, weil damit qualitativ gelabelte Situationsdaten entstehen, die durch kontinuierliche Fuzzy-Clustering der situativ dynamischen Prozesszustände automatisch generiert werden.

Diese schließen die Lücke zwischen der Dynamik der Prozessdaten und der Notwendigkeit des Vorliegens gelabelter Daten. Das Schließen dieser Lücke ist deswegen so wichtig, weil damit erstmalig die Voraussetzung zum Einsatz von künstlichen neuronalen Netzen zur Optimierung von Geschäftsprozessen geschaffen wird.

### Einfacher Einstieg in Deep Qualicision

Aus der Perspektive des Kunden ist der Einstieg in ein solches Szenario denkbar einfach. Soll die Deep Qualicision KI zur Optimierung oder auch zur Analyse eines Geschäftsprozesses eingesetzt werden, so ist abzufragen, nach welchen Kennzahlen und Kriterien (KPIs) die Qualität des Geschäftsprozesses bewertet und optimiert werden soll.

Klassische KPIs in Produktionsprozessen sind Effizienzkriterien, wie Termintreue, Auslastung der Ressourcen oder die Verfügbarkeit von Kapazitäten und von Material. Weitere Kriterien können sein: Mitarbeiterzufriedenheit, Gleichmäßigkeit des Ressourceneinsatzes oder Prozessstabilität. Hinzu kommen Bewertungen der Produktvarianz, die Streuung der Auftragsstruktur und die Entwicklung der genannten KPIs über die Zeit, auch im Sinne der Nutzbarkeit von historisierten Daten.

Die in dem beschriebenen Sinne zusammenzutragenden Informationen sind zunächst lediglich eine organisatorische und keine prinzipielle Herausforderung. Es ist sozusagen das Pflichtprogramm eines jeden Vorhabens, die Abläufe in einem Geschäftsprozess zu verbessern. Die Kür kommt dann mit den Automatismen von Deep Qualicision.

### Lediglich Geschäftsprozessdaten und KPI-Festlegungen als Eingabe

Sind die KPIs einmal beschrieben und liegen die Rohdaten des Geschäftsprozesses vor, so kann Deep Qualicision durch die Anwendung von Optimierungsalgorithmen die Geschäftsprozessdaten labeln, die Abläufe optimieren und die gelernten Labels zum maschinellen Lernen der positiven und negativen Gesetzmäßigkeiten des jeweiligen Geschäftsprozesses nutzen.

ning umgesetzt und durch eine Neuronale-Netze-Komponente zum Lernen basierend auf den qualitativ gelabelten Prozessdaten erweitert.


Das Ergebnis sind positiv und negativ gelabelte Prozessdaten und Prozesszustände, die die Basis für das maschinelle Lernen dafür darstellen, in welchen Prozesssituationen in Zukunft die Prozessoptimierung wie agieren soll.

### Selbsttätiger Ablauf des Qualitativen Labels

Der Vorteil ist dabei einerseits, dass der Vorgang des Labels selbsttätig durch die Optimierung selbst gesteuert abläuft und im Wesentlichen keinen menschlichen Input bis auf die Definition der KPIs benötigt. Andererseits ist unmittelbar ersichtlich, dass das Schema von Deep Qualicision auf jeden mittels Qualicision bereits optimierten Geschäftsprozess anwendbar ist.

Letztgenannter Vorteil ist deshalb so wichtig, weil jede bisher existierende Qualicision-Applikation mit dem maschinellen Lernen von Deep Qualicision

ausgestattet werden kann. Insbesondere können so alle mit Qualicision ausgestatteten PSI-Softwareprodukte die Deep Qualicision-basierte maschinelle Lernfähigkeit erhalten. In einigen der Lösungen sind gegebenenfalls weitere KPIs festzulegen, nach denen in Zukunft zusätzlich qualitativ gelabelt und maschinell gelernt werden soll. Genau dies ist ein weiterer Vorteil. In jedes der PSI-Softwareprodukte können auch weitere KPIs hinzugefügt und über das Deep-Qualicision-Framework zur Verbesserung oder auch zur Abrundung bestehender Funktionalitäten eingesetzt werden.



Die Architektur von Deep Qualicision.

Das Gelernte dann in einem neuronalen Netz abzuspeichern, ist unter Nutzung des automatisierten Labels direkt möglich. Der prinzipielle Aufbau einer Deep-Qualicision-Lösung und ihrer Bestandteile sind in Abbildung 1 (siehe Kasten) dargestellt.

Es ist unmittelbar erkennbar, dass Deep Qualicision aus einer originären Qualicision-Optimierungslösung besteht, die nunmehr auch zusätzlich zum qualitativen Labeln der Prozessdaten benutzt wird. Weiterhin wird mittels eines intelligenten zielkonfliktorientierten Clusterverfahrens ein KPI-orientiertes Reinforcement-Lear-

## Sequenzierung in der Automobilproduktion

Eine der ersten Kundenanwendungen, bei der das Verfahren in seinen Grundzügen zum Einsatz kam, ist die Optimierung von Produktionssequenzen in der Automobilproduktion basierend auf den sogenannten Planzeiten. Die hier festgelegten KPIs leiten sich ab aus den Arbeitszeiten von Tätigkeiten und Abläufen in jeder der Arbeitsstationen entlang einer Montagelinie. Die zu produzierenden Fahrzeuge sind so in Sequenz zu stellen, dass keine der Arbeitszeiten-KPIs ihre Kapazitätsobergrenzen überschreiten. Kann eine Überschreitung punktuell nicht vermieden werden, so muss unmittelbar im Anschluss eine Arbeitszeitentlastung sichergestellt werden, indem in der Sequenz auf Fahrzeuge mit komplexen Tätigkeiten Fahrzeuge mit weniger komplexen Arbeitsinhalten folgen. Da dies für alle erdenklichen Situationen für alle Auftragskombinationen sicherzustellen ist, ist die Optimierung der Produktionssequenzen bei weitem komplexer als etwa bekannte strategische Spiele wie Poker, Schach oder Go.

## Unbekannte Dynamik der Auftragsdaten kein Hindernis

Über die Kombinatorik hinaus hat die Sequenzierung wie fast alle Produktionsprozesse die Unbekannte der Zusammensetzung der Auftragsmengen und ihrer dynamischen Variantenvielfalt. Damit ist die Komplexität der hier notwendigen Optimierung auf eine noch anspruchsvollere Stufe gestellt.

Bei mehreren tausend Produktionsaufträgen pro Tag und bei der astro-

nomischen Variantenvielfalt an Ausstattungsmerkmalen und über 100 zu optimierenden KPIs ist dies unmittelbar ersichtlich. Daher ist auch das qualitative automatische Labeln der Prozessdaten unerlässlich. Nur dank dieser lassen sich die erreichte Lernfähigkeit der Deep-Qualicision-Lösungen und die nötige Prozessstabilität sicherstellen, wobei sich das Verfahren in der Automobilindustrie an mehreren Produktionslinien bereits im produktiven Einsatz befindet.

hunderte von Mitarbeitern zu verteilen.

## Maschinelles Lernen für alle PSI-Softwaretools

Deep Qualicision wird hier als Zusatzfunktionalität eines zuschaltbaren maschinellen Lernverfahrens um eine bereits laufende PSIcommand-Lösung gelegt. Sowohl die technische als auch die inhaltliche Zuschaltung der Deep Qualicision KI stellt die Blaupause der Integration des maschinellen




Das Deep Qualicision Framework.

## Fieldforce Management im PSIcommand

Ein weiterer Use-Case, diesmal in Verbindung mit dem Softwaretool PSIcommand, ist der Einsatz von Deep Qualicision zum Lernen der Einstellparameter der Field-Force-Optimierung bei der Wartung und Entstörung von Stromnetzen.

Die hier zugrunde liegenden KPIs beschreiben die Effizienz der Zuordnung von Ressourcen zu Einsätzen. Auch hier liegt die Anzahl der KPIs zusammen mit etlichen Hilfs-KPIs im Bereich von einhundert. Pro Jahr sind mehr als einhunderttausend Wartungs- und Entstörungseinsätze auf

len Lernens in alle PSI-Softwaretools dar, die bereits mit einer Qualicision-Optimierung ausgestattet sind. Damit steht maschinelles Lernen mit Hilfe des Deep-Qualicision-Frameworks z.B. für die PSI-Produkte PSITraffic/BMS, PSIcommand, PSI SASO, PSIPenta/MES, PSIasm, PSIwms und natürlich für alle Softwareprodukte von PSI FLS zur Verfügung. 

### PSI FLS

Fuzzy Logik & Neuro Systeme GmbH

Dr. Rudolf Felix

Geschäftsführer

Telefon: +49 231 9700921

felix@fuzzy.de

www.qualicision.de