

Produktbericht: Produktionsprozesse in Echtzeit oder in planenden oder simulierenden Szenarien optimieren Vorausschauende Optimierung mit Deep Qualicision

Deep Qualicision verbindet die Optimierungsmaschine Qualicision mit zielkonfliktbasiertem maschinellen Lernen und neuronalen Netzen. Dieses Lösungsprinzip lernt effizient Parameter so einzustellen, dass vorausschauend optimiert werden kann.

Die Anwendung Deep Qualicision lässt sich einsetzen, um aus Einzelentscheidungen effizient multikriterielle Entscheidungen unter konsistenter Beachtung von Zielkonflikten in zu optimierenden Businessprozessen zu bestimmen. Zusätzlich lassen sich die Prioritäten der Kriterien so lernen, dass konsistente Prioritäteneinstellungen der Kriterien und Ziele (KPIs) automatisch empfohlen werden (siehe Abbildung 1).

Anwender den Produktionsprozess wahlweise in Echtzeit oder im Sinne von planenden oder simulierenden Szenarien optimieren.

Ungleichheiten ausbalancieren

Ein in der Praxis sehr häufig vorkommendes Szenario besteht darin, dass zwischen den im Prozess vorliegenden Annahmen über die Leistungsparameter der Produktionsressourcen und der Realität im Prozessalltag mitunter bedeutsame Abweichungen bestehen.

vermeidbaren Anstrengungen sind, die gegebenenfalls präventiv behandelt werden könnten.

Untersuchungen zeigen, dass die genannten Abweichungen zum einen aus einem Mix an spontan auftretenden Anomalien des Prozesses bestehen. Diese Anomalien entstehen mit nicht planbaren Ausfällen von Ressourcen, qualitätsbedingten Sperrungen oder mit Zulieferausfällen sowie durchaus auch mit dem sich spontan veränderndem Auftragsmix.

Aus Vergangenheitsdaten lernen

Zum anderen zeigen die gleichen Untersuchungen, dass neben den spontanen Anomalien ebenfalls strukturell bedingte Abweichungen zwischen dem Plan- und dem Ist-Prozess existieren, die für die Prozessbetreiber regelmäßig erst im Nachhinein auffallen. Besser wäre ein Szenario, in dem die strukturellen regelmäßigen Anomalien aus Vergangenheitsdaten automatisch erlernbar wären.

Bei Deep Qualicision-basierter vorausschauender Vorbeugung (Predictive Prevention) werden Produktionssequenzen der Vergangenheit analysiert und mit der in den originären Qualicision-Lösungen enthaltenen KPI-orientierten Optimierungen verknüpft. Die Qualicision-Zielkonfliktanalyse wird

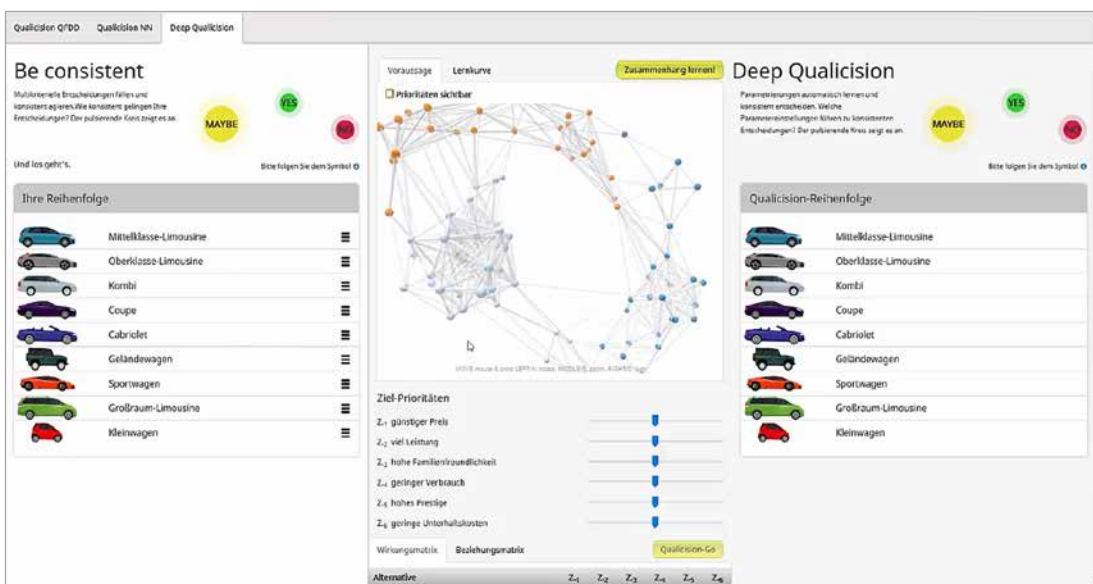


Abbildung 1 zeigt konsistente Prioritäteneinstellungen der Kriterien und Ziele (KPIs) im Deep Qualicision.

Damit lässt sich mit Deep Qualicision der tiefere Zusammenhang zwischen Einzelentscheidungen und den Zielkriterien softwaregestützt herstellen. Im Falle der Anwendung dieses Prinzips auf das Thema des Scheduling von Produktionsaufträgen kann der

Zahlreiche industrielle Anwendungen bestätigen, dass die Qualicision-Realzeitoptimierung diese zwar erfolgreich ausbalancieren kann, jedoch die Abweichungen beispielsweise in Form von Unterschieden zwischen Plan- und Ist-Sequenzen Gegenstand von

ender Vorbeugung (Predictive Prevention) werden Produktionssequenzen der Vergangenheit analysiert und mit der in den originären Qualicision-Lösungen enthaltenen KPI-orientierten Optimierungen verknüpft. Die Qualicision-Zielkonfliktanalyse wird

um die automatische Erkennung von Anomalien erweitert.

Mittels Maschinellen Lernen werden Eigenchaftsklassen von Produkten und Ressourcen aus vergangenen Produktionssequenzen gelernt, die mit strukturellen Anomalien einhergehen. Die gelernten Klassen stellen die systematischen Anomalien dar. Anschließend ist es möglich, die Anomalien in Optimierungsziele für den Qualicision-Optimierungsalgorithmus so zu übersetzen, dass die Optimierung zusätzlich die systematischen Anomalien ausbalanciert, falls

die Ressourcen des zu optimierenden Produktionsprozesses dafür vorhanden sind. Die Anomalien werden sozusagen mit Hilfe der gelernten Zusammenhänge beseitigt.

In Abbildung 2 ist die Anwendung der gelernten Klassenbildung auf ein einfaches Demonstrationsbeispiel bestehend aus dem Bilden von Fahrzeugsequenzen für das Ranking im Rahmen von Kaufentscheidungsprozessen dargestellt.

Ranking von Entscheidungsalternativen

Bei zu modellierenden Entscheidungen geht es hier darum, für eine Kaufentscheidung eines Autos ein Ranking von Entscheidungsalternativen an Autotypen so zu erstellen, dass das Ranking möglichst viele Kriterien erfüllt, die einem wichtig sind. Vereinfacht betrachtet ist ein solches Ranking vergleichbar mit einer Pro-

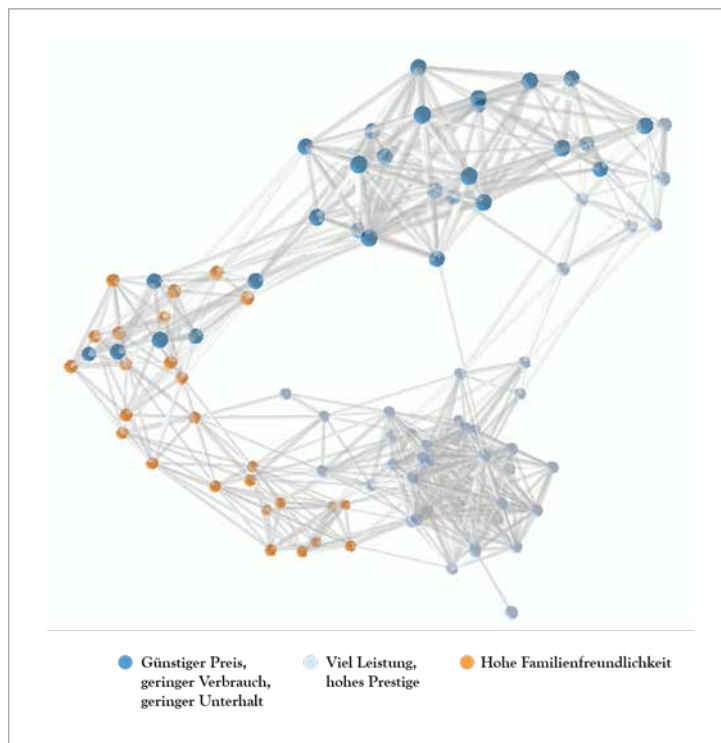


Abbildung 2 zeigt die konsistenten Klassen von Entscheidungsalternativen und Rankings.

duktionsreihenfolge, in welcher Reihenfolge die im Ranking angeordneten Autotypen vorgesehen sind.

Die Autotypen sind Kleinwagen, Coupé, Cabrio, Mittelklasse-Limousine, Oberklasse-Limousine, Großraum-Limousine, Kombiwagen, Sportwagen und Geländewagen. Kriterien, die bei der Entscheidung eine Rolle spielen, sind im Demonstrationsbeispiel günstiger Preis, viel Leistung, geringer Verbrauch, hohe Familienfreundlichkeit, hohes Prestige und geringe Unterhaltskosten (siehe Abbildung 2). Diese Kriterien sind mit Produktionskriterien vergleichbar, nach denen die Reihenfolge gebildet wird.

Bildet der Kaufentscheider ein Ranking der besagten Autotypen nach einem Entscheidungsziel, so sind mit dem Ranking die restlichen Kriterien als Einzelentscheidungsziele mehr oder minder implizit erfüllt oder nicht erfüllt. Bestimmte andere Ziele wer-

den dadurch gegebenenfalls indirekt verneint oder außer Acht gelassen. So tendiert beispielsweise ein Ranking, das den Kleinwagen und den Kombiwagen an den ersten Stellen aufweist eher pro günstigen Preis und pro geringen Verbrauch und eventuell leicht pro Familienfreundlichkeit. Rankings, die den Sportwagen und das Cabrio voranstellen, sprechen eher für viel Leistung und vielleicht für den Wunsch nach etwas mehr Prestige und ignorieren das Kriterium des günstigen Preises. Das Ziel des günstigen Preises ist

dabei sogar in gewisser Weise negiert. Treten nun in einem Ranking Reihenfolgen auf, die zueinander negierte Kriterien implizieren, so werden diese als inkonsistente Anomalien durch das Verfahren automatisch erkannt und in ihrer Struktur gelernt.

Insgesamt kombiniert das Deep Qualicision-basierte Verfahren der vorausschauenden Sequenzierung die bisherigen Vorteile von Qualicision-Optimierungen mit der Möglichkeit systematische Anomalien in Produktionsprozessen automatisch zu erkennen. Erste Anwendungsszenarien mit realen Produktionsdaten zeigen bereits Erfolge. ☺

PSI FLS
Fuzzy Logik & Neuro Systeme GmbH
Dr. Rudolf Felix
Geschäftsführer
Telefon: +49 231 9700921
felix@fuzzy.de
www.qualicision.de