

## MLinPPC

Steigerung der Planungsqualität durch den Einsatz von maschinellem Lernen in der Produktionsplanung und -steuerung

<b>Programm / Ausschreibung</b>	Produktion der Zukunft, Produktion der Zukunft, 32. AS PdZ - Nationale Projekte 2019	<b>Status</b>	abgeschlossen
<b>Projektstart</b>	01.05.2020	<b>Projektende</b>	31.10.2023
<b>Zeitraum</b>	2020 - 2023	<b>Projektlaufzeit</b>	42 Monate
<b>Keywords</b>	Machine Learning; Produktionsplanung; Planungsqualität;		

### Projektbeschreibung

Ausgangssituation: In der industriellen Praxis kommt es immer wieder zu Abweichungen zwischen der Produktionsplanung (d.h. der Planzahl) und der späteren Ausführung. Diese Abweichungen werden durch Unsicherheiten verursacht, wie beispielsweise ungenaue oder unzureichende Planungsdaten (z.B. Datenqualität und -verfügbarkeit), ungeeignete Planungs- und Steuerungssysteme oder unvorhersehbare Ereignisse. Produktionsplaner verwenden daher Puffer in Form von Beständen oder verlängerten Übergangszeiten, um Möglichkeiten zur Durchführung korrigierender Maßnahmen in der Produktionssteuerung zu schaffen. Puffer führen jedoch zu erhöhtem Koordinations- und Steuerungsaufwand und zu negativen Auswirkungen, u.a. auf Bestand, Durchlaufzeit und Auslastung. Darüber hinaus konnte nachgewiesen werden, dass die Zuverlässigkeit der Produktionspläne und damit die Planungsqualität (PQ) in den ersten drei Tagen nach Planerstellung auf bis zu 25% abfallen kann [1]. Potenziale für eine effektivere Planung bleiben weitgehend ungenutzt. Ziel von MLinPPC ist die Verbesserung der Planungsqualität in der Produktionsplanung und -steuerung mit Hilfe von Machine Learning (ML) Algorithmen. Hierdurch ist es möglich, die Abweichung zwischen den Stammdaten und den prognostizierten Ist-Daten im Jahr 2023 um ca. 50% gegenüber dem Stand der Technik im Jahr 2019 zu reduzieren. Dieses beinhaltet zudem eine Reduktion des WIP (ca. -30%), der Durchlaufzeit (ca. -20%) und des Steuerungsaufwands (ca. 10%) bei gleichzeitiger Erhöhung der Auslastung (ca. +5%-10%) und Termintreue (ca. 30%).

Ergebnis ist ein Proof-of-Concept Demonstrator eines Planungsunterstützungssystems mit den folgenden Aspekten:

- Verfahren zur kontinuierlichen Verbesserung von Stammdaten unter Verwendung von ML-Algorithmen, die ebenfalls zur Prognose der zukünftigen Plandaten genutzt werden
- Definition des Begriffs "Planungsqualität" und Bestimmung der dazugehörigen Kennzahl (als neue KPI) inklusive definierter Berechnungsformel
- Eine Methode zur Unterstützung des Planers durch Generierung und Visualisierung von Verbesserungsvorschlägen zur Erhöhung der Planungsqualität
- Verfahren zur Generierung von Produktionsplänen mit hoher Planungsqualität durch zwei unterschiedliche methodische Ansätze (evolutionär und funktionsbasiert unter Verwendung dynamischer Zeitanteile), sowie deren Evaluierung entsprechend der Effektivität, Anwendbarkeit, Rechenzeit und Nachvollziehbarkeit durch den Menschen

- Standardisierte "Feature Collection" zur Generierung von Merkmalen für die ML Algorithmen basierend auf dem Typ des Produktionssystems, identifizierten Einflussfaktoren und Eigenschaften des Produktionssystems.

## **Abstract**

Initial situation: In industrial practice, there are always deviations between production planning and subsequent execution. These deviations are caused by uncertainties, e.g. inaccurate or insufficient planning data (e.g. data quality and availability), inappropriate planning and control systems or unforeseeable events. Production planners therefore use buffers in the form of inventories or extended transitional periods to create possibilities for implementing corrective measures in production control. Buffers, however, lead to increased coordination and control effort and to negative effects, e.g. on inventory, throughput time and capacity utilization. Furthermore, it was found that the reliability of the production plans and thus the planning quality (PQ) can drop to 25% in the first three days after plan creation [1]. Potential for more effective planning remains largely unexploited.

The objective of MLinPPC is to improve planning quality in production planning and control with the aid of machine learning (ML) algorithms. This makes it possible to reduce the deviation between the master data and the forecast actual data in 2022 by approx. 50% compared to the state of the art in 2018. This also includes a reduction of the WIP (approx. -30%), the lead time (approx. -20%) and the control effort (approx. 10%) with simultaneous increase of the utilization (approx. +5%-10%) and adherence to schedules (approx. 30%).

The result is a proof-of-concept demonstrator of a planning support system with the following aspects:

- Process for the continuous improvement of master data using ML algorithms, which are also used to forecast future planning data.
- Method for determining and calculating the planning quality based on the definition of the key figure (as a new KPI).
- A method to support the planner by generating and visualizing improvement suggestions to increase the planning quality.
- Procedures for generating production plans with high planning quality through two different methodological approaches (evolutionary and function-based using dynamic time components), as well as their evaluation according to effectiveness, applicability, computing time and traceability by humans.
- Standardized "Feature Collection" for the generation of features for the ML algorithms based on the type of production system, identified influencing factors and properties of the production system.

## **Endberichtkurzfassung**

In industrial practice, there are always deviations between production planning and subsequent execution. These deviations are caused by uncertainties, e.g. inaccurate or insufficient planning data (e.g. data quality and availability), inappropriate planning and control systems or unforeseeable events (e.g. machine breakdown, illness, late delivery). Production planners therefore use buffers in the form of inventories or extended transitional periods to create possibilities for implementing corrective measures in production control. Buffers, however, lead to increased coordination and control effort and to negative effects, e.g. on inventory, throughput time and capacity utilisation.

The MLinPPC project has shown, that dynamic planning data predicted by machine learning (ML) algorithms can be integrated into existing production planning and scheduling (PPS) processes and can lead to higher performance of the production system. The overall project objective was to increase the planning quality with the help of ML. Based on the main

goal of the project the following sub-objectives were formulated: i) Reduction of the work in progress, lead time and administrative costs; ii) Increase of utilisation and timeliness.

Benefits with more accurate planning data could be demonstrated in the project. Master data accuracy could be increased by 10% for lead times. Using the more reliable dynamic master data made it possible to reduce energy consumption by 6% and manual efforts by 3%. However, industrialization, scaling up and bringing the solution to a higher TRL level include several challenges and companies have to consider their own workflows and strategies.

### **Projektkoordinator**

- Fraunhofer Austria Research GmbH

### **Projektpartner**

- Institute For Computer Science And Control - SZTAKI
- voestalpine BÖHLER Bleche GmbH & Co KG
- AT & S Austria Technologie & Systemtechnik Aktiengesellschaft