

# Ein hybrider Ansatz zur Einteilung der Mitarbeiter in der Smart Factory

André Horst Lippok<sup>1</sup>, Clemens Schönherr<sup>1</sup>

IPRI - International Performance Research Institute<sup>1</sup>

## Zusammenfassung

Zurzeit wird oft maschinelles Lernen als Ersatz von Experten betrachtet. Wir zeigen wie ein Hybridansatz, der sowohl Experten als auch maschinelles Lernen verwendet, Mitarbeiter in einer Smart Factory automatisch einteilen kann. Dies führt zu einem effizienteren Start und ermöglicht eine zusätzliche Qualitätskontrolle der Trainingsdaten. Wir zeigen als erstes, dass bei einer kleinen Datenbasis Expertenwissen die Daten unterstützt. Als zweites wird eine Methode dargestellt wie das Expertenwissen als ein zusätzliches Qualitätsmerkmal für neue Daten benutzt werden können.

## 1 Einleitung

Mit der Integration von Sensorik in halbautomatisierten Smart Factories, können diese selbständig Probleme und Schäden erkennen und melden (Kang et al. 2016, S. 115). Jedoch müssen die Aufgaben, welche die Probleme und Schäden lösen sollen, oft von Menschen ausgeführt werden. Dazu muss die Factory ermitteln, welche Kompetenzen benötigt werden und die dazugehörigen Mitarbeiter ermitteln, bzw. welche Rolle im Unternehmen die richtige ist. Rolle ist dabei eine Position im Unternehmen mit bestimmten Aufgabenbereichen. Beispiele für Rollen sind Einrichter, Bediener, Vorarbeiter usw.

Traditionell werden vom Management den Mitarbeitern Regeln nach dem Top-Down Prinzip vorgegeben, welche Rolle welche Aufgabe ausführen sollte (Liu et al. 2008, S. 466). Dabei muss das Management alle möglichen Situationen und Details berücksichtigen. Das führt dazu, dass wichtige Situationen übersehen werden und unvollständige Regeln vorgegeben werden können (Sargano et al. 2017). Des Weiteren können Regeln auch eine idealistische Natur haben und so für die praktische Umsetzung in der Fabrik ungeeignet sein (Lin et al. 2014).

Einen umgekehrter Ansatz folgt dem Bottom-Up Prinzip. Für jedes Ereignis wird von den Mitarbeitern, Vorgesetzten oder Experten hinterher bestimmt, welche Rolle für die jeweilige Aufgabe die richtige gewesen wäre. Dabei ist ein Ereignis eine Situation, in der die Factory

den Mitarbeitern eine Aufgabe gegeben hat. Also gibt die Factory eine Aufgabe vor und bestimmt daraus welche Rolle diese ausführen soll, daraufhin wird die Aufgabe ausgeführt. Hinterher wird von jemanden entschieden, welche Rolle für diese Aufgabe am geeignetsten gewesen wäre, falls die Factory falsch entschied. Mit diesem Feedback wird ein Lernalgorithmus trainiert, sodass die Factory in Zukunft eine bessere Auswahl der Rollen treffen kann. Das ist ein ähnliches Vorgehen wie in (Liu et al. 2008, 466f.) beschrieben und verifiziert wurde.

Beim Bottom-Up Prinzip benötigt der Lernalgorithmus Daten über die auszuführenden Aufgaben. Der Algorithmus muss Korrelationen finden anhand dessen er erkennen kann, welche Rolle geeignet ist. Ohne eine Datenbasis kann der Algorithmus keine Prognosen treffen. Welche Daten nötig sind hängt von den Aufgaben ab. Beispielsweise müssen bei der Reparatur von Maschinen, Daten vorliegen, die zeigen was repariert werden muss und wie komplex die Reparatur ist. Die Daten müssen somit ein ausreichend gutes Bild von den nötigen Aufgaben liefern.

Hier soll ein hybrider Ansatz verfolgt werden. Die Grundlage bildet zunächst das Top-Down Prinzip. Hierbei werden die Regeln von Experten, welche Rolle für welche Aufgaben unter welchen Bedingungen geeignet ist, festgelegt. Auch werden mögliche Datenquellen für die spätere Phase festgelegt. Daraufhin werden die Expertenregeln in die Smart Factory eingespielt. Sodass den Mitarbeitern von der Factory vorgegeben wird, welche Rolle welche Aufgaben ausführen sollen. Daraufhin wird dem System Input in Form von Feedback gegeben, welche Rolle geeignet gewesen wäre. Also wird jetzt nach dem Bottom-Up Prinzip agiert. Neue Regeln werden anhand der Expertenregeln und dem Input der Mitarbeiter entwickelt. Diese Phase konkretisiert, korrigiert und erweitert die Regeln der Experten.

## 2 Theorie

### 2.1 Rahmenbedingungen

Die Smart Factory erkennt vollautomatisch Probleme, Qualitätsverschlechterung und Schäden und führt selbständig analytische Prozesse durch, wie z. B. Predictive Maintenance. Auch die Lösungen werden automatisch gefunden. Jedoch können viele der Lösungen nicht automatisch ausgeführt werden, sondern benötigen menschliche Mitarbeiter zur Durchführung.

Es wird davon ausgegangen, dass die Experten die nötigen oder möglicherweise nötigen Datenquellen ausreichend ermitteln können. Jedoch müssen sie nicht genau wissen welche Daten nötig sind. Unnötige Datenquellen sind erlaubt, jedoch dürfen wichtige Datenquellen nicht fehlen, da sonst wesentliche Parameter nicht berücksichtigt werden können, die in der Produktion entstehen

Auch wird davon ausgegangen, dass das Verhältnis zwischen den Aufgaben und den richtigen Mitarbeitern deterministisch ist. Also dass dieselbe Aufgabe (mit selben

Schwierigkeitsgrad usw.) die gleiche Rolle benötigt, wie z. B. der Austausch von Maschinenkomponenten.

## 2.2 Vergleich Bottom-Up mit Hybrid bei wenig Daten

Wie oben besprochen hat das Top-Down Prinzip Probleme alle Situationen zu definieren. Die Regeln der Experten sind somit fehlerhafte Approximationen der richtigen unbekanntes Regeln. Dafür können die Regeln ganzheitlicher sein als im Bottom-Up. Somit stellen diese Regeln eine gute Approximation dar.

Bottom-Up hat aber ebenfalls Probleme. Das Feedback kann widersprüchlich sein. Auch kann es fehlerhaft sein, da Mitarbeiter Situationen unterschiedlich einschätzen (Culverhouse et al. 2003). Seltene Ereignisse haben oft nur wenige Daten, sodass die Daten ungleichmäßig verteilt sind. Ein Lernalgorithmus kann somit seltene Ereignisse nur schlecht beschreiben (Hall 1999, S. 2).

Da die Regeln der Experten der Top-Down Phase bereits eine gute Approximation der Realität bieten, soll dies als Ausgangspunkt genommen werden. Damit sind die Regeln zu Beginn besser als ein reines Bottom-Up Prinzip (Kuhnert et al. 2010). Da ein Lernalgorithmus nur Daten verwendet, werden künstliche Daten aus den Expertenregeln generiert.

Zur Veranschaulichung, warum das Hybridprinzip besser ist, soll in Abbildung 1 ein vereinfachtes Beispiel dargestellt werden. Hierbei versucht ein Lernalgorithmus eine komplizierte Funktion zu erlernen. Die zu erlernende Funktion wurde als schwarze durchgezogene Linie dargestellt. Die graue gestrichelte Linie ist die Approximation durch den Lernalgorithmus. Beim Bottom-Up Prinzip fängt der Lernalgorithmus bei null an. Beim Hybridprinzip haben Experten bereits eine leicht fehlerhafte Funktion prognostiziert.

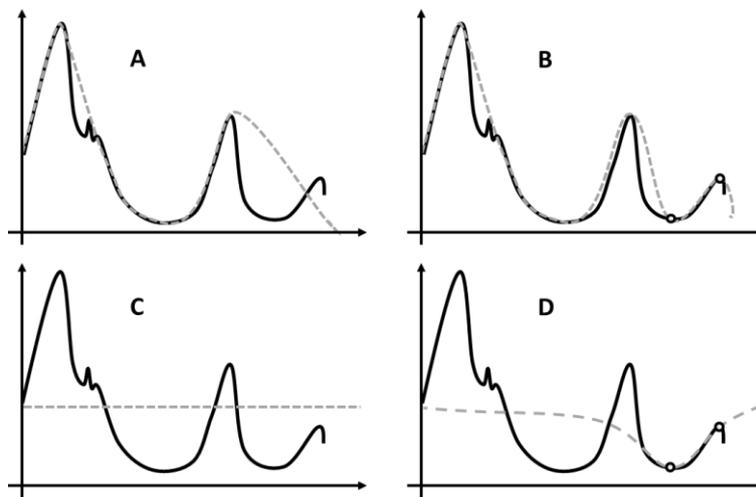


Abbildung 1 Vergleich Bottom-Up mit und ohne Expertenregeln: Die schwarze durchgezogene Linie ist die wirkliche Verteilung. Gestrichelte Linie ist die Verteilung wie es der Lernalgorithmus gelernt hat. A: Nur Experten. B: Experten und zwei Datenpunkte. C: Ohne Experten und ohne Daten. D: Zwei Datenpunkte ohne Experten.

In Abbildung 1 wird das Hybridprinzip mit dem Bottom-Up-Prinzip verglichen. Wenn genügend Daten vorhanden sind, dann gibt es keinen Unterschied mehr. Wenn jedoch nicht ausreichend Daten verfügbar sind, dann ist das Hybridprinzip besser. In A ist der Zustand des Lernalgorithmus noch bevor Daten erhoben wurden, also ein reines Top-Down-Prinzip, zu sehen. In C ist zu sehen, wie der Bottom-Up startet, noch bevor irgendwelches Feedback gekommen ist. Somit ist zu Beginn das Bottom-Up-Prinzip nicht funktionsfähig.

In B sind zwei Datenpunkte zum Top-Down-Prinzip dazugekommen, somit ist es jetzt im Hybridprinzip. In D sind auch zwei Datenpunkte zum Bottom-Up-Prinzip hinzugekommen. Auch hier ist der hybride Ansatz immer noch besser. Mit zunehmenden Daten verschwindet der Unterschied, da im Hybridprinzip die Rolle der Expertenregeln sich zunehmend verringert, da der Anteil der aus den Expertenregeln generierten Daten verschwindet.

Zu beachten ist auch, dass selbst wenn viele Daten erhoben wurden, die Daten seltene Bereiche oft nur schlecht abdecken können und somit in diesen Bereichen die Expertenregeln weiterhin dominieren (Kuhnert et al. 2010). In reinen Bottom-Up-Prinzip sind solche Bereiche nicht ausreichend abgedeckt und verhalten sich unvorhersehbar.

### 2.3 Verwendung der Expertenregeln zum Überprüfen der Daten

Bei großen Datenmengen ist das Überprüfen der Sinnhaftigkeit der Daten problematisch. Bei einem reinen Bottom-Up-Vorgehen können die Daten nur auf Konsistenz überprüft werden. So können Ausreißer erkannt werden (Liu et al. 2004). Wenn jedoch neben den Daten im Hybridansatz auch noch Expertenregeln vorhanden sind, dann können Diskrepanzen zwischen Expertenregeln und Daten automatisch gefunden werden. Auch können neue Daten

darauf überprüft werden, in wie fern sie sich von dem bisherigen Modell unterscheiden. Das ermöglicht ein Bewerten der Diskrepanzen und Entscheidungen können getroffen werden, ob die Experten oder die Daten korrekt sind.

Wenn ein bestehendes Modell mit neuen Trainingsdaten verglichen werden soll, kann wie folgt vorgegangen werden:

Die neuen Trainingsdaten besitzen Labels  $l_r$ . Das Modell wird jetzt auf die neuen Trainingsdaten angewendet. Dadurch besitzen alle Datenpunkte ein richtiges Label  $l_r$  und das durch das Modell prognostizierte Label  $l_p$ . Jetzt wird ein neues Label  $l_z$  eingeführt, das durch

$$l_z = \begin{cases} 1, & \text{wenn } l_r = l_p \\ 0, & \text{wenn } l_r \neq l_p \end{cases}$$

definiert ist. Somit kann ein neues Modell  $M_z$  trainiert werden, das die neuen Daten mit dem Label  $l_z$ , aber nicht  $l_r$  oder  $l_p$ , beinhaltet. Somit wird ein Modell trainiert, das Diskrepanzen zwischen den neuen Trainingsdaten und dem Modell erlernt.

Das Modell muss ein transparentes Modell sein, wie zum Beispiel Entscheidungsbäume, da sonst die Diskrepanzen nicht ersichtlich sind. Dadurch kann mit einem Entscheidungsbaum Regeln dargestellt werden, welche im Konflikt mit den Expertenregeln stehen. Das befähigt Menschen Fehler aufzudecken. So zeigte (Klein et al. 1997, S. 169–194), dass Menschen in der Aufgabe der Fehlererkennung effizient sein können. Jedoch muss die Darstellung der Fehler für Menschen geeignet sein, darum wird ein Entscheidungsbaum zum Erkennen der Fehler herangezogen.

### 3 Umsetzung

Durch die Definition einer Smart Factory, besitzt diese ein Regelwerk zur Steuerung der Produktionsmaschinen. Das Regelwerk ist der Teil, der Probleme und Lösungen findet, und so den Mitarbeitern Aufgaben delegiert. Jedoch legt das Regelwerk nicht fest welche Rolle die Aufgabe ausführen soll. In dieser Arbeit wird davon ausgegangen, dass bereits ein Regelwerk existiert, da dies nicht im Fokus der Arbeit liegt.

Zuerst werden Regeln von Experten Top-Down festgelegt. Zu diesen Regeln werden künstliche Daten erzeugt, die gleichmäßig die Regeln abbilden. Dazu werden alle Variablen in den Regeln uniform variiert. Dies wird gemacht, da typische Lernalgorithmen nur Datenpunkte, in Form von Beispielen, verstehen können. Dann wird der Lernalgorithmus zum ersten Mal trainiert.

Daraufhin beginnt die Bottom-Up Phase. Sie wird in Abbildung 2 dargestellt. In Abbildung 2 wird der Aufbau zur Findung der Rollen dargestellt. Zunächst gibt das Regelwerk der Factory eine Aufgabe vor. Der Lernalgorithmus entscheidet, welche Rolle die Aufgabe ausführen soll. Das Ergebnis und eine ID wird dem Mitarbeiter mitgeteilt, sodass der Mitarbeiter mit der richtigen Rolle die Aufgabe ausführt. Die ID ist eine Zahl, die die

Aufgabe zu diesem Zeitpunkt eindeutig identifiziert. Die Daten die der Lernalgorithmus verwendet, sowie das Ergebnis und die ID werden in einer Datenbank abgespeichert, des Weiteren wird dieses Ereignis dokumentiert.

Zu einem späteren Zeitpunkt, gibt ein Mitarbeiter in einer höheren Hierachiestufe diesem Ereignis Feedback. Das Feedback teilt mit, welche Rolle die richtige zu diesem konkreten Zeitpunkt gewesen wäre. Dazu wird die ID verwendet, sodass der Lernalgorithmus die Richtige Rolle den Daten in der Datenbank zuordnen kann. Das Feedback und alle Daten werden in einer Datenbank gespeichert.

Der Lernalgorithmus selbst ist ein Entscheidungsbaum, da die Regeln nicht als besonders komplex erwartet werden. Außerdem ist die benötigte Datenmenge bei Entscheidungsbaume nicht besonders hoch. Jedoch können auch andere Algorithmen Verwendung finden. Der Lernalgorithmus wird regelmäßig mit der Datenbank trainiert. Dadurch kann sich der Algorithmus stetig weiter entwickeln und somit die reale Welt abbilden.

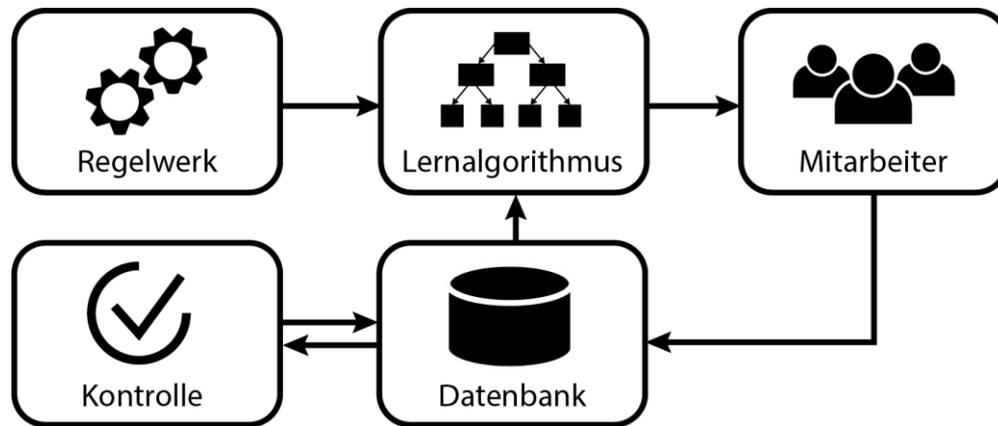


Abbildung 2 Framework: Das Regelwerk gibt Aufgaben vor. Der Lernalgorithmus ermittelt welche Rolle die Aufgabe ausführen soll. Später wird Feedback gegeben welche Rolle die richtige gewesen wäre. Dies wird in einer Datenbank gespeichert und für das Trainieren des Lernalgorithmus verwendet.

## 4 Fazit

Damit maschinelles Lernen erfolgreich in einer Smart Factory die Mitarbeiter einteilen und dem richtigen Personal Aufgaben zuordnen kann, sind Experten notwendig. Sie werden benötigt um:

- die Datenbasis festzulegen, ohne die der Algorithmus nicht funktionieren kann
- eine erste Approximation der unbekanntnen Regeln zu entwickeln, damit zu Beginn die Smart Factory nicht unvorhersehbar reagiert
- um die Anzahl der nötigen Daten zu reduzieren
- die Sinnhaftigkeit neuer Daten zu bewerten

**Danksagung:** Dieses Forschungs- und Entwicklungsprojekt wird/wurde mit Mitteln des Bundesministeriums für Bildung und Forschung (BMBF) im Programm „Innovationen für die Produktion, Dienstleistung und Arbeit von morgen“ gefördert und vom Projektträger Karlsruhe (PTKA) betreut. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.



Die Autoren bedanken sich bei Federn Brand KG, Wafios AG, CIRP GmbH, Dreher GmbH, Gewatec GmbH, ASI datamyte GmbH, Fraunhofer IPA und IPEK Karlsruhe für Ihre Unterstützung.

## 5 Literaturverzeichnis

- Culverhouse, P. F., Williams, R., Reguera, B., Herry, V. & González-Gil, S. (2003). Do experts make mistakes? A comparison of human and machine identification of dinoflagellates. *Marine Ecology Progress Series* 247, 17–25.
- Hall, M. A. (1999). *Correlation-based feature selection for machine learning*, The University of Waikato.
- Kang, H. S., Lee, J. Y., Choi, S., Kim, H., Park, J. H., Son, J. Y., Kim, B. H. & Noh, S. D. (2016). Smart manufacturing. Past research, present findings, and future directions. *INTERNATIONAL JOURNAL OF PRECISION ENGINEERING AND MANUFACTURING-GREEN TECHNOLOGY* 3 (1), 111–128. doi:10.1007/s40684-016-0015-5
- Klein, B. D., Goodhue, D. L. & Davis, G. B. (1997). Can humans detect errors in data? Impact of base rates, incentives, and goals. *MIS Quarterly*, 169–194.
- Kuhnert, P. M., Martin, T. G. & Griffiths, S. P. (2010). A guide to eliciting and using expert knowledge in Bayesian ecological models. *Ecology letters* 13 (7), 900–914. doi:10.1111/j.1461-0248.2010.01477.x
- Lin, V. S., Goodwin, P. & Song, H. (2014). Accuracy and bias of experts' adjusted forecasts. *Annals of Tourism Research* 48, 156–174. doi:10.1016/j.annals.2014.06.005
- Liu, H., Shah, S. & Jiang, W. (2004). On-line outlier detection and data cleaning. *Computers & Chemical Engineering* 28 (9), 1635–1647. doi:10.1016/j.compchemeng.2004.01.009

- Liu, Y., Wang, J., Yang, Y. & Sun, J. (2008). A semi-automatic approach for workflow staff assignment. *Computers in Industry* 59 (5), 463–476. doi:10.1016/j.compind.2007.12.002
- Sargano, A., Angelov, P. & Habib, Z. (2017). A Comprehensive Review on Handcrafted and Learning-Based Action Representation Approaches for Human Activity Recognition. *Applied Sciences* 7 (1), 110. doi:10.3390/app7010110

## Autoren



### **Lippok, André**

André Lippok studierte Physik mit dem Schwerpunkt theoretische Kernphysik und Computergestützte Physik an der Eberhard Karls Universität Tübingen. Derzeit arbeitet er als wissenschaftlicher Mitarbeiter beim International Performance Research Institute (IPRI) als Unterstützung im Bereich Mathematik und Informatik.



### **Schönherr, Clemens**

Clemens Schönherr studierte Wirtschaftswissenschaften mit dem Schwerpunkt Informatik an der Universität Ulm. Derzeit arbeitet er als wissenschaftlicher Mitarbeiter beim International Performance Research Institute (IPRI) in Stuttgart und ist Projektkoordinator für das BMBF Verbundprojekt IQ4.0.