

# **Entwicklung einer integrierten Lösung für das Data Farming und die Wissensentdeckung in Simulationsdaten**

## ***Development of an Integrated Solution for Data Farming and Knowledge Discovery in Simulation Data***

Jonas Genath, Sören Bergmann, Niclas Feldkamp, TU Ilmenau, Ilmenau(Germany),  
jonas.genath@tu-ilmenau.de, soeren.bergmann@tu-ilmenau.de,  
niclas.feldkamp@tu-ilmenau.de

Sven Spieckermann, Stephan Stauber, Simplan AG, Hanau (Germany),  
sven.spieckermann@simplan.de, stephan.stauber@simplan.de

**Abstract:** Simulation is an established methodology for planning and evaluating manufacturing and logistics systems. In contrast to classical simulation studies, the method of knowledge discovery in simulation data uses a simulation model as a data generator (data farming). Subsequently, hidden, previously unknown and potentially useful cause-effect relationships can be uncovered on the generated data using data mining and visual analytics methods. So far, however, there is a lack of integrated, easy-to-use software solutions for the application of the data farming in operational practice. This paper presents such an integrated solution, which allows for generating experiment designs, implements a method to distribute the necessary experiment runs, and provides the user with tools to analyze and visualize the result data.

## **1 Einleitung**

Simulation ist ein etabliertes Werkzeug zur Planung und Steuerung komplexer Produktions- und Logistiksysteme und hat sich unter anderem hinsichtlich der Herausforderungen im Kontext der Industrie 4.0 als eine wichtige Schlüsselkomponente erwiesen (Krückhans und Meier 2013). Der Ablauf traditioneller Simulationsstudien ist üblicherweise darauf ausgelegt, durch manuelles Experimentieren einen vorher definierten Projektumfang abzudecken oder ein konkretes (Projekt-)Ziel zu erreichen. Darunter fällt z. B. die Optimierung eines Fertigungslayouts (Law 2003).

Mit steigender Rechenleistung und der allgemeinen Verfügbarkeit von Big-Data-Infrastrukturen und cloudbasierten Lösungen sowie erheblichen Fortschritten auf dem Gebiet des Data Mining ergibt sich eine weitere Anwendungsmöglichkeit für

Simulationsmodelle: Das Durchführen einer sehr großen Bandbreite von Experimenten, um versteckte, vorher unbekannte und möglicherweise nützliche Wirkzusammenhänge aufzudecken. Gerade in komplexen Systemen können möglicherweise Beziehungen, Probleme oder sogar Lösungen vorhanden sein, die über das definierte Projektziel einer klassischen Simulationsstudie hinausgehen, aber dennoch oder gerade deshalb zur Entscheidungsunterstützung beitragen können. Grundlage bildet hierbei die Methodik des Data Farming (Horne und Meyer 2010).

Ein Vorgehensmodell, speziell für die Analyse von Produktions- und Logistiksystemen, das die Methode des Data Farmings aufgreift und mit Methoden des Data Mining und der Visual Analytics ergänzt, wurde von Feldkamp et al. (2017) unter dem Namen Wissensentdeckung in Simulationsmodellen entwickelt. Erste Fallstudien haben erhebliche Potentiale aufgezeigt (Feldkamp et al. 2020a; Feldkamp 2020).

Ein breiter Transfer in die betriebliche Praxis scheitert bisher am Fehlen einer integrierten Softwarelösung, die auch Nicht-Simulations- bzw. Data-Farming-Experten befähigt, Wissensentdeckung in Simulationsmodellen zu betreiben.

In diesem Beitrag wird eine derartige integrierte Lösung vorgestellt, die als neues Modul (4farm) die bestehende Softwarelösung SimAssist (vgl. Sokoll und Clausing 2020) zunächst prototypisch erweitert. Die Entwicklung erfolgte im Rahmen des BMBF-Forschungsprojekts „Entwicklung einer integrierten Lösung für das Data Farming und die Wissensentdeckung in Simulationsdaten (DaWiS)“. Die zu betrachtenden Teilaspekte sind hierbei: Verfahren des intelligenten Experimentdesigns, Methoden zur (cloudbasierten) Verteilung der Experimente sowie die Auswahl und Adaption geeigneter Data-Mining- und Visual-Analytics-Methoden, so dass mit geringem Einarbeitungsaufwand effektiv Data Farming bzw. die Methode der Wissensentdeckung in Simulationsmodellen nach Feldkamp (2020) angewendet werden kann.

Im Rahmen dieses Beitrags werden die Methode und die implementierte Softwarelösung anhand eines Beispiels aus der Automobilbranche erläutert. Die eigentliche Simulation erfolgt exemplarisch in der verbreiteten Simulationssoftware Siemens Plant Simulation.

Die folgenden Kapitel dieses Beitrags gliedern sich wie folgt: Zunächst werden der Stand der Forschung und die notwendigen theoretischen Grundlagen des Data Farming und der Methode zur Wissensentdeckung in Simulationsdaten (Knowledge Discovery in Simulation Data – KDS) kurz dargestellt. Darauf folgend wird im Hauptteil des Beitrags die integrierte Methode schrittweise, den Teilaspekten folgend, vorgestellt und durch ein Workflow-Beispiel illustriert. An den entsprechenden Stellen wird hierbei insbesondere auf die technische Umsetzung eingegangen. Der Beitrag wird mit einem Fazit sowie einem Ausblick auf mögliche Erweiterungen der integrierten Lösung abgeschlossen.

## 2 Grundlagen und Stand der Forschung

Beim so genannten Data Farming wird ein vorab validiertes Simulationsmodell als Datengenerator genutzt, um mit Hilfe von intelligentem Experimentdesign und High Performance Computing ein möglichst großes oder gar vollständiges Spektrum an Modell- bzw. Systemverhalten (Wirkungsraum) abdecken zu können (Sanchez

2007; Horne und Meyer 2010). Die „Farming“-Metapher drückt hierbei aus, dass analog zu einem Farmer, der sein Land möglichst effizient kultiviert, um seinen Ernteertrag zu maximieren, beim Data Farming das Ziel ist, den Datenertrag des Simulationsmodells zu maximieren (Sanchez 2014).

Entscheidend ist hierbei unter anderem die Forschung zu verbesserten Verfahren für die Gestaltung von Simulationsexperimentplänen. Diese erlauben mögliche Wertekombinationen von Eingabeparametern umfassend abzubilden und garantieren trotzdem gleichzeitig eine vertretbare Datenmenge und Zahl von Experimentläufen (Kleijnen et al. 2005; Sanchez und Wan 2009). Gerade im Kontext der Simulation von Produktions- und Logistiksystemen ist die Auswahl einer der Designmethoden oder sogar die Auswahl einer geeigneten Kombination von verschiedenen Designmethoden von großer Bedeutung. Zur Durchführung der Experimente wird in der Data-Farming-Literatur oft auf entsprechendes High Performance Computing verwiesen (Horne und Meyer 2010).

Auf der erzeugten Datenbasis können dann mit Hilfe von verschiedenen Data-Mining- bzw. Visual-Analytics-Methoden interessante Zusammenhänge in den erzeugten Daten aufgedeckt werden (Keim et al. 2008). So können möglicherweise bisher unbekannt Beziehungen, Probleme oder sogar Lösungen identifiziert werden. Eine Auswahl möglicher Data-Mining-Methoden, z. B. das Clustering, und das Wechselspiel der Methoden untereinander stellt Feldkamp (2020) vor. Empfohlen wird hierbei, dass die eigentliche Analyse der generierten Simulationsergebnisdaten sowie die Beziehungen zwischen Eingangsparametern (Faktoren) und Ergebnisdaten (Kennzahlen) idealerweise mit interaktiver, visueller Analyse unterstützt wird. Visualisierung ist allgemein ein entscheidendes Werkzeug, wenn eine Interpretation von Daten gefordert ist. Eine konsequente Verzahnung, wie es allgemein in der Forschungsdisziplin Visual Analytics empfohlen wird, zwischen interaktiver Visualisierung, z. B. mittels interaktiv adaptierbare Animationen, Zeitreihendiagramm, Graphen, und der Datenanalyse mittels Data-Mining-Methoden ermöglicht dem Anwender, die menschliche Fähigkeit zur Schlussfolgerung bestmöglich einzubringen (Keim et al. 2008; Feldkamp et al. 2020b).

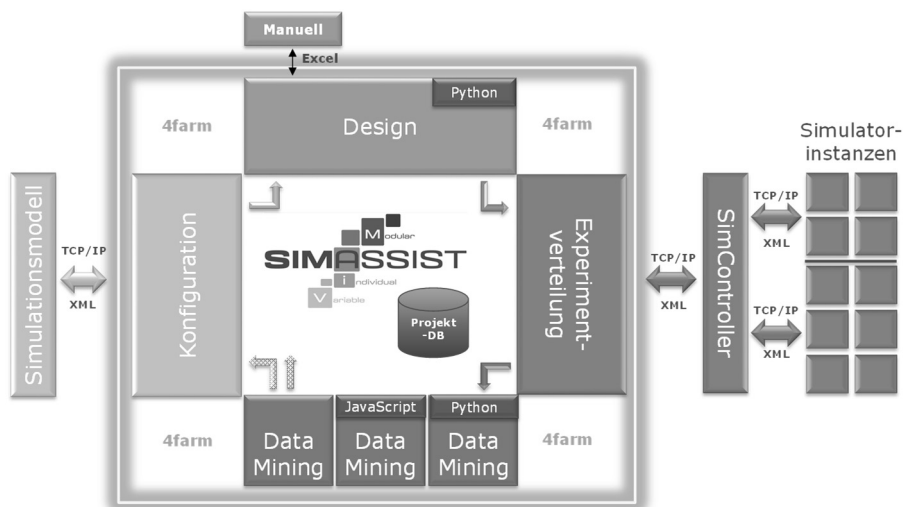
Zusammenfassend ist zum Stand von Wissenschaft und Technik einzuschätzen, dass die grundlegenden Einzelmethoden (Data Farming, Intelligentes Experimentdesign, Data Mining und Visual Analytics) im Stand der Forschung durchaus einen guten Stand erreicht haben. Auch erste erfolgversprechende prototypische Anwendungen im Kontext der Simulation von Produktions- und Logistiksystemen sind publiziert worden. Es ist aber zu konstatieren, dass es bisher keine ganzheitliche Lösung zur Übertragung der Methoden als Ganzes oder zumindest in wesentlichen Teilen in ein von Nicht-Experten bedienbares Framework gibt, welches zudem auf den Bereich der Simulation in Produktion und Logistik fokussiert. Darüber hinaus fehlen Methoden zur (Teil-)Automatisierung der Prozesse und zur Unterstützung von Nicht-Experten im Allgemeinen.

### 3 Integrierte Lösung für das Data Farming und die Wissensentdeckung in Simulationsdaten

Wie in der Einleitung bereits erwähnt, ist das Ziel des BMBF-Forschungsprojekts DaWiS die Entwicklung einer Softwarelösung, ergänzt durch Best-Practice-Vorgehensweisen, welche es auch Nicht-Experten erlaubt, Wissen auf Basis von Data Farming mittels Data-Mining- und Visual-Analytics-Methoden zu erwerben.

Hierzu wird die erprobte modular aufgebaute Software SimAssist (vgl. Sokoll und Clausning 2020) der Simplan AG, welche bisher bereits umfangreiche Assistenzfunktionen zur Verwaltung, Analyse, Visualisierung und Dokumentation von Ergebnisdaten klassischer Simulationsprojekte bereitstellt, erweitert. Die Erweiterungen werden hierbei in einem neuen Modul (4farm) zusammengefasst. So werden jeweils für die bereits angesprochenen Teilaspekte, dem intelligenten Experimentdesign, der Verteilung von Experimenten sowie für das Data Mining und Visual Analytics, entsprechende Komponenten konzipiert und prototypisch implementiert. Die grundlegende Architektur des Moduls ist Abbildung 1 zu entnehmen.

Vorab ist zu bemerken, dass insgesamt bei der Konzeption und Entwicklung hohe Anforderungen an die Gestaltung der Nutzerinteraktionen gestellt werden, sodass alle nötigen Teilaspekte (vom Experimentdesign über die Verteilung der Experimentläufe bis hin zur Analyse und Visualisierung der Daten) ohne Wechsel der Software über eine integrierte Oberfläche verfügbar sind.



**Abbildung 1:** Grobarchitektur der Softwarelösung (SimAssist – 4farm-Modul) für das Data Farming und die Wissensentdeckung in Simulationsdaten

Des Weiteren werden vor dem Endanwender möglichst viele technische Details insbesondere des Experimentdesigns, der Data-Mining- und Visual-Analytics-Methoden verborgen oder die erforderlichen Entscheidungen werden basierend auf Best-Practices vorweggenommen. Ist dies nicht möglich, werden die nötigen Einstellungen auf eine intuitiv verständliche fachliche Anwendungsebene


transferiert. Dies geschieht, indem erforderliche Parameter bei der Nutzung der Methoden abgefragt werden. Dabei werden dem Nutzer jeweils Listen mit Auswahlmöglichkeiten angeboten. Die entsprechenden Hinweise zur Nutzung sowie den Vor- und Nachteilen der einzelnen Varianten sind in der Software in Form von Informationstexten oder Entscheidungsbäumen o. ä. hinterlegt. Der Anwender kann sich somit vollständig auf das Modell und die fachliche Aufgabe fokussieren.

Aufgrund der sich rasant weiterentwickelnden Forschung im Bereich des Data Mining und Visual Analytics aber auch der Vielzahl an Möglichkeiten bezüglich des Experimentdesigns ist eine weitere an die Software gestellte Anforderung die Eigenschaft, dass in Zukunft leicht neue Methoden inklusive Visualisierungen über einen standardisierten Mechanismus hinzugefügt werden können.

### 3.1 Workflow-Beispiel – Versorgung einer PKW-Produktionslinie mit Batterien

Im Rahmen dieses Beitrags werden ausgewählte Methoden sowie die implementierte Softwarelösung – insbesondere die Auszüge der Nutzeroberflächen – anhand eines Beispielszenarios vorgestellt. Unter anderem wurde dieses Beispiel im DaWiS-Projekt von der Anforderungsanalyse bis zur Demonstration der Methoden und der Software genutzt.

Das Workflow-Beispiel umfasst eine typische logistische Problemstellung, in welcher die Versorgung einer laufenden PKW-Produktion mit zwei verschiedenen Batterietypen sowie die Entsorgung der anfallenden leeren Ladungsträger betrachtet wird. Die Lieferung der Batterien in Ladungsträgern und die Abholung der leeren Ladungsträger erfolgt per LKW an einem Entladedock. Die eigentliche Handhabung der Batterien erfolgt durch Gabelstapler (Abbildung 2).



**Abbildung 2:** Bildschirmausschnitt des Modells einer Be-/Entladung von Batterien zur Versorgung einer laufenden Produktion.

Zu den variierbaren Eingangsparametern (Faktoren) des Modells gehören der Anteil der Batterietypen A (PAR\_Produktion\_AnteilA) und B (PAR\_ProduktionAnteilB) am gesamten Produktionsprogramm der angeschlossenen Fahrzeugmontage (die

selbst nicht Teil des betrachteten Simulationsmodells ist). Weitere Faktoren des Simulationsmodells sind das Gesamtproduktionsvolumen (PAR\_Produktionsvolumen), die Zyklen, in welchen LKWs neue Batterien anliefern (PAR\_ZykluszeitA, PAR\_ZykluszeitB) sowie die Größe der Puffer für Vollgut (PAR\_Pufferplätze\_Vollgut). Zudem sind vier verschiedene Szenarien (PAR\_Szenarien) definiert, die sich je durch die genutzten Staplervarianten (5t- bzw. 8t-Stapler) und Stapleranzahlen (1–3 Stapler) unterscheiden. Zur Analyse der Ergebnisse werden 31 Ergebnisparameter gespeichert, u. a. die Staplerauslastungen oder die Stillstandzeiten der angeschlossenen Montage aufgrund fehlender Batterien.

Für die eigentliche Modellierung des Produktions- und Logistiksystems, mit der Software Siemens Plant Simulation, wurden Bausteine entwickelt, welche das Setzen der Faktoren (Stellgrößen) sowie das Auslesen der vorab definierbaren Ergebnisdaten (XML-Format) ermöglichen. Mit Hilfe dieser Bausteine können Modelle mit Metainformationen über die Faktoren und Ergebnisparameter sowie deren Datentypen und gegebenenfalls vorhandene Wertebereiche angereichert werden. Diese Informationen können durch die integrierte Lösung ausgewertet und dem Nutzer präsentiert und als Grundlage z. B. für das konkrete Experimentdesign genutzt werden.

### 3.2 Experimentdesign

Wie bereits beschrieben, ist das Generieren geeigneter Experimentpläne die erste große Herausforderung im Prozess des Data Farmings und somit auch bei der darauf aufbauenden Methode zur Wissensentdeckung in Simulationsdaten. Aktuell wurden fünf verschiedenen Experimentdesignmethoden ausgewählt und implementiert: das vollfaktorielle Design, das  $2^k$  Design, das Central Composite Design und das Latin Hypercube Sampling (LHS) sowie ein Design, in welchem ein LHS mit einem weiteren Faktor bzw. Design gekreuzt werden kann.

Zu beachten ist, dass Experimentdesignmethoden neben den Parametern, welche die Faktoren beschreiben, also den Namen der Faktoren, dem Datentyp und Wertebereich des Faktors mitunter auch methodenspezifische Parameter benötigen. So muss etwa beim LHS die Zahl der Experimente angegeben werden. Alle Designmethoden sind als Python-Skripte realisiert. Die Skripte nutzen hierbei eine einheitliche Bibliothek für den XML-basierten Datenimport und -export und können zu Beginn entsprechende Metainformationen als Kommentare enthalten. Die Informationen über die Faktoren können manuell gesetzt werden oder – wie im vorherigen Abschnitt angedeutet – aus dem Simulationsmodell ausgelesen werden. Die designmethodenspezifischen Parameter werden in SimAssist beim Nutzer abgefragt. Welche Parameter abgefragt werden und wie sich die Oberfläche im 4farm-Modul gestaltet, wird in den Metainformationen des jeweiligen Skriptes definiert. Ein Beispiel ist in Abbildung 3 zu sehen, in der eine gekreuztes LHS parametrisiert wird.

Das Hinzufügen weiterer Experimentdesignmethoden ist jederzeit auch ohne Neustart der Software möglich. Hierzu müssen die Methoden nur als mit den angesprochenen Metainformationen annotierte Python-Skripte durch Kopieren in ein festgelegtes Verzeichnis bekannt gemacht werden (sogenanntes Hot-Deployment). Die entsprechende Auswahlmöglichkeit und auch die Oberflächen werden ad hoc generiert und können sofort genutzt werden.

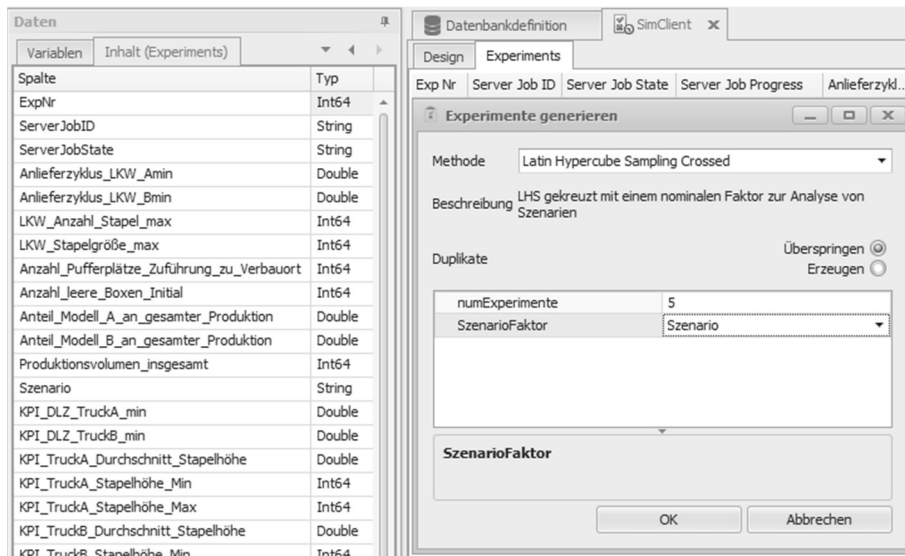


Abbildung 3: Ausschnitt der Oberfläche der Experimentdesignkomponente des 4farm Moduls

Bei der Auswahl der Experimentdesignmethoden wird der Nutzer zu einem durch Hilfetexte zu den einzelnen Methoden unterstützt. Zum anderen ist eine Hilfestellung in Form eines Entscheidungsbaums (Abbildung 4) vorhanden, in welchen durch die Beantwortung einfacher Fragen eine Designmethode vorgeschlagen wird. Im hier angesprochenen Beispielszenario wurde auf Grund der verschiedenen Szenarien ein gekreuztes LHS-Design mit 15.000 Experimenten (5000 LHS \* 3 Szenarien) angewendet (grüner/gestrichelter Pfad in Abbildung 4).

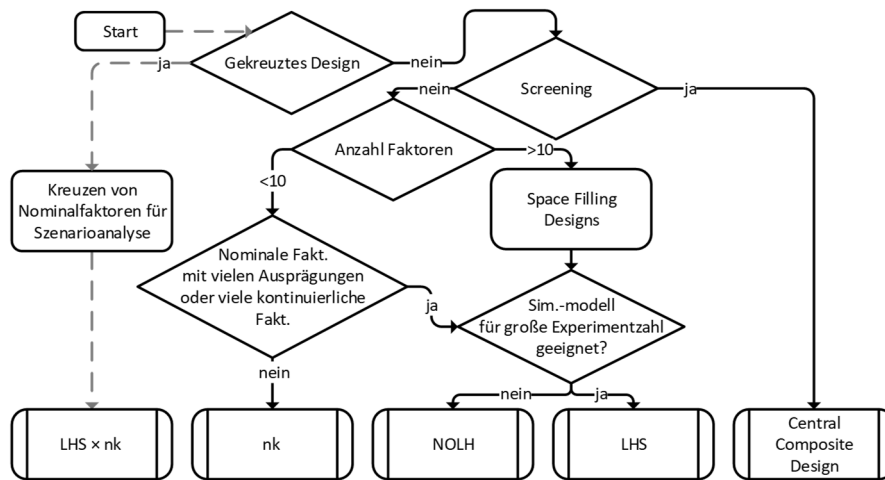


Abbildung 4: Flowchart zur Auswahl geeigneter Experimentdesignmethoden

### 3.3 Experimentverteilung

Die Durchführung der Experimente im Data Farming ist auf Grund der recht hohen Anzahl an Simulationsläufen auf einer einzelnen Recheninstanz (einzelner Rechner bzw. einzelner Prozessorkern auf einem einzelnen Rechner) meist nicht sinnvoll. Wünschenswert ist vielmehr das Verteilen einzelner Experimente auf verschiedene Recheninstanzen. Die im DaWiS Projekt genutzte Technologie basiert hierbei auf einer aus einem Vorprojekt der Simplan AG stammenden Softwarekomponente, dem so genannten SimController. Dieser wurde so angepasst, dass es nun möglich ist, Experimente, d. h. Modelle und die konkreten Faktorenwerte in Form von XML-Daten über eine zentrale Instanz auf sich selbst registrierende Clientinstanzen mittels TCP/IP zu verteilen. Die einzelnen Instanzen melden laufend ihren Status. Nach Durchlauf eines Experimentes werden die definierten Kennwerte (und genutzten Faktorwerte) an die zentrale Instanz zurückgemeldet und in Form einer SQLite Datenbank in SimAssist gespeichert. Diese Daten können im Anschluss sehr unkompliziert weiter genutzt und analysiert werden. Die Oberfläche der Experimentverteilung, in welcher u. a. der aktuelle Bearbeitungsfortschritt und die Ergebnisdaten zu sehen sind, ist Abbildung 5 zu entnehmen.

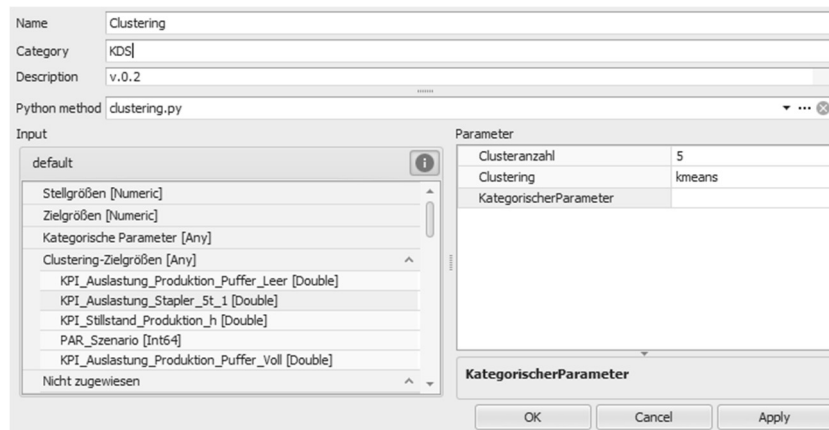
Design		Experiments				
Exp Nr	Server J...	Server Job ...	Server Job Progress	KPI_DLZ_Truck A...	KPI_DLZ_Truck B...	KPI_Verbrauch_Pr...
51	1723	Finished	100 %	3721,18622324097	7862,89464324...	54264
50	1724	Started	71 %			
49	1725	Started	72 %			
48	1726	Finished	100 %	2931,70201137141	8109,91975358...	54264
47	1727	Started	0 %			

Abbildung 5: Ausschnitt der Oberfläche der Experimentverteilungskomponente

### 3.4 Analyse der Ergebnisdaten - Data Mining und Visual Analytics

Analog zu den Experimentdesignmethoden ist die Zahl möglicher Data Mining Methoden und Visualisierungsmethoden sehr groß. Im Vorgehensmodell zur Wissensentdeckung in Simulationsdaten analysiert Feldkamp (2020) verschiedene Gruppen von Methoden und gewichtet diese bzgl. ihres Nutzens für die Wissensentdeckung. Aufbauend auf dieser Forschung wurden Verfahren der deskriptiven Statistik, der Korrelationsanalyse, zum Clustering (k-means und gaussian mixture) sowie zur Regressionsanalyse und zur Bildung von Klassifizierungsbäumen als für die praktische Anwendung am wertvollsten eingestuft und im Prototyp implementiert. Hinzu kommen jeweils geeignete Visualisierungen wie Heatmaps für die Korrelationsanalyse oder Parallelkoordinaten- und Streudiagramme für die Auswertung geclusterter Daten. Die technische Umsetzung erfolgt hierbei analog der Umsetzung der Experimentdesignmethoden, d. h. jede der Methoden ist als annotiertes Python-Skript realisiert und der Datenaustausch mit dem Skript erfolgt wiederum per XML-Format. Auch hier ist es somit einfach möglich, weitere Data-Mining-Methoden und Visualisierungen zu implementieren, welche dem Anwender sofort über generische Dialoge aus dem 4farm-Modul zur Wissensentdeckung zur Verfügung stehen. Beispielhaft ist ein Dialog, hier zum Starten der Clusteranalyse auf den Daten des Workflow-Beispiels, in Abbildung 6 zu sehen.





**Abbildung 6:** Ausschnitt der Oberfläche der Data-Mining-Komponente des 4farm-Moduls

Die Datenanalysen des Workflow-Beispiels sind aktuell noch nicht vollständig abgeschlossen. Erste Erkenntnisse zeichnen sich aber ab. Es kristallisiert sich z. B. heraus, dass bei Annahme des aktuellen Bedarfs an Batterien jedes Szenario zu einer sicheren Versorgung der Produktion führt, aber bereits bei moderat steigenden Anteilen an batterieelektrischen Fahrzeugen, insbesondere wenn ein Batterietyp deutlich häufiger nachgefragt wird, Szenarien mit zwei Staplern, wobei mindestens einer ein 8t Stapler ist, besser funktionieren.

## 4 Fazit und Ausblick

Der Beitrag stellt eine sich in Entwicklung befindende integrierte Softwarelösung für die Wissensentdeckung in Simulationsdaten vor. Hierzu wurden der Bedarf für und die Anforderungen an eine solche Lösung hergeleitet sowie die wesentlichen Teilaspekte der Methode und ihre nutzerfreundliche prototypische Umsetzung näher betrachtet. Weitere Entwicklungsschritte sind u. a. die Implementierung weiterer Experimentdesign- und Data-Mining-Methoden sowie zusätzlicher Visualisierungen. Zudem sind weitere Tests in Anwendungsfällen aus der Praxis nötig, insbesondere um die implementierten Schnittstellen und Datei-Formate zu validieren. Des Weiteren sind Forschungen zur weiteren (Teil-) Automatisierung der Data-Mining-Methoden, z. B. mittels Meta-Learning zu Bestimmung geeigneter Hyperparameter, oder auch die Nutzung von Methoden zur Robustheitsanalyse denkbar.

## Danksagung

Das DaWiS Forschungsprojekt wird gefördert vom Bundesministerium für Bildung und Forschung. Die Förderung startete im Januar 2020 und wird 2 Jahre dauern.



Bundesministerium  
für Bildung  
und Forschung

## Literatur

- Feldkamp, N.: Wissensentdeckung im Kontext der Produktionssimulation. Ilmenau: Universitätsverlag Ilmenau 2020.
- Feldkamp, N.; Bergmann, S.; Strassburger, S.: Knowledge Discovery in Simulation Data. *ACM Transactions on Modeling and Computer Simulation* 30 (2020a) 4, S. 1–25.
- Feldkamp, N.; Bergmann, S.; Strassburger, S.: Visualization and Interaction for Knowledge Discovery in Simulation Data. In: Bui, T. (Hrsg.): *Proceedings of the 53rd Hawaii International Conference on System Sciences, Maui, 7-10.01, 2020, 2020b*, S. 1340–1349.
- Feldkamp, N.; Bergmann, S.; Straßburger, S.; Schulze, T.: Data Farming im Kontext von Produktion und Logistik. In: Wenzel, S.; Peter, T. (Hrsg.): *Simulation in Produktion und Logistik 2017, Kassel, 20-22.09, 2017*, S. 169–178.
- Horne, G.E.; Meyer, T.: Data farming and defense applications. In: Armstrong, R.; McNamara, J.; Pinelli, T.E. (Hrsg.): *MODSIM World Conference and Expo, Hampton, VA, USA, 13-15.10, 2010*, S. 74–82.
- Keim, D.A.; Mansmann, F.; Schneidewind, J.; Thomas, J.; Ziegler, H.: Visual Analytics: Scope and Challenges. In: Simoff, S.J.; Böhlen, M.H.; Mazeika, A. (Hrsg.): *Visual Data Mining. Berlin, Heidelberg: Springer 2008*, S. 76–90.
- Kleijnen, J.P.; Sanchez, S.M.; Lucas, T.W.; Cioppa, T.M.: State-of-the-Art Review: A User's Guide to the Brave New World of Designing Simulation Experiments. *INFORMS Journal on Computing* 17 (2005) 3, S. 263–289.
- Krückhans, B.; Meier, H.: Industrie 4.0 – Handlungsfelder der Digitalen Fabrik zur Optimierung der Ressourceneffizienz in der Produktion. In: Dangelmaier, W.; Laroque, C.; Klaas, A. (Hrsg.): *Proceeding der 15. ASIM Fachtagung Simulation in Produktion und Logistik 2013, Paderborn, 09.-11.10, 2013*, S. 31–40.
- Law, A.M.: How to conduct a successful simulation study. In: Chick, S.; Sanchez, P.J.; Ferrin, D.; Morrice, D.J. (Hrsg.): *Proceedings of the 2003 Winter Simulation Conference, New Orleans, LA, USA, 7.12-10.12, 2003*, S. 66–70.
- Sanchez, S.M.: Work Smarter, Not Harder: Guidelines for Designing Simulation Experiments. In: Henderson, S.G.; Biller, B.; Hsieh, M.-H.; Shortle, J.; Tew, J.D.; Barton, R.R. (Hrsg.): *Proceedings of the 2007 Winter Simulation Conference, Washington, DC, USA, 9-12.12, 2007*, S. 84–94.
- Sanchez, S.M.: Simulation Experiments: Better Data, Not Just Big Data. In: Tolk, A.; Diallo, S.D.; Ryzhov, I.O.; Yilmaz, L.; Buckley, S.; Miller, J.A. (Hrsg.): *Proceedings of the 2014 Winter Simulation Conference, Savannah GA, 7.12.-10.12., 2014*, S. 805–816.
- Sanchez, S.M.; Wan, H.: Better than a petaflop: The power of efficient experimental design. In: Rossetti, M.D.; Hill, R.R.; Johansson, B.; Dunkin A.; Ingalls, R.G. (Hrsg.): *Proceedings of the 2009 Winter Simulation Conference (WSC 2009), Austin, TX, 13.-16. Dezember, 2009*, S. 60–74.
- Sokoll, K.; Clausung, M.: Methoden und Werkzeuge der Simulationsassistentz. In: Mayer, G.; Pöge, C.; Spieckermann, S.; Wenzel, S. (Hrsg.): *Ablaufsimulation in der Automobilindustrie. Berlin: Springer Vieweg 2020*, S. 349–364.