



## **Bayes'sche Verfahren zur Optimierung von diskreten, ereignisorientierten Simulationen in Produktion und Logistik - Weiterentwicklung, Anwendung und Transfer bestehender Methoden auf ausgewählte Parametrisierungsprobleme der Praxis**

### **Beteiligte**

Philipp Zmijewski, Prof. Dr. Nicolas Meseth

### **Problemstellung**

Komplexe und dynamische Problemstellungen in Produktion und Logistik werden immer öfter mittels computergestützter Simulationen modelliert, um Entscheider datengetrieben zu unterstützen. Der Entscheider kann im Simulationsmodell gewisse "Stellschrauben" (Parameter) einstellen und das Ergebnis der Simulation bewerten. Die "optimale" Einstellung der Stellschrauben (Parametrisierung) wird anschließend auf die reale Problemstellung übertragen. Problematisch ist hierbei, neben der realitätsgetreuen Modellierung, die Identifikation der optimalen Parametrisierung. Die Anzahl an Kombinationen erreicht schnell ein Maß, welches rein menschlich nicht mehr praktikabel überblickt werden kann.<sup>1</sup>

Klassische mathematische Verfahren, wie die Analysis, scheitern an solchen Problemstellungen, da keine analytische Beschreibung der Zielfunktion vorliegt. Daher wird die Simulation als mathematische "Black-Box" betrachtet. Charakteristisch hierbei ist, dass nur Input-Out Beziehungen beobachtet, bzw. gemessen werden können.

Bestehende Algorithmen zur Optimierung von Black-Box Problemen sind u.a. die "simulierte Abkühlung" oder genetische Algorithmen. Diese Algorithmen weisen allerdings Defizite in der praktischen Anwendung auf, da sie eine hohe Anzahl an Evaluationen der Black-Box benötigen, um adäquate Lösungen zu generieren (Kochenderfer und Wheeler (2019)).<sup>2</sup>

Hier soll das Promotionsvorhaben anschließen. Bayes'sche Optimierungsverfahren haben bereits in anderen Disziplinen mit Black-Box-Problemen, wie dem Hyperparameter-tuning des maschinellen Lernens, gute Ergebnisse generiert und gelten dort seitdem als "state-of-the-art" (Shahriari et. al. (2015)). Sie werden den Surrogate Optimierungsverfahren<sup>3</sup> zugeordnet und weisen eine besondere Stichprobeneffizienz sowie eine hohe Konvergenzgeschwindigkeit auf (Bergenkamp, Schoelling und Krause (2019)).

Da es einige Analogien zwischen den bestehenden Anwendungsgebieten der Bayes'schen Optimierungsverfahren und der Simulationsoptimierung gibt, lässt sich theoretisieren, dass diese auch zur Lösung von Simulationsproblemen in Produktion und Logistik geeignet sind.

---

<sup>1</sup> 5 Stellschrauben mit je 100 diskreten Ausprägungen ergeben bereits 1000000000 mögliche Kombinationen.

<sup>2</sup> Evaluation meint hier die Simulation eines Modells mit einer definierten Parametrisierung. Je nach Modell und Rechenleistung dauert eine Evaluation wenige Sekunden bis einige Minuten. Die genannten Verfahren benötigen je nach Problem bis zu mehreren tausend Evaluationen.

<sup>3</sup> Zur Erläuterung siehe:

<https://towardsdatascience.com/an-introduction-to-surrogate-optimization-intuition-illustration-case-study-and-the-code-5d9364aed51b> (Zugriff am 14.10.2021)



### **Ziel des Projekts**

Es soll untersucht werden, ob Bayes'sche Optimierungsverfahren gängige Problemstellungen in Produktion und Logistik, welche mittels diskreter, ereignisorientierter Simulation modelliert werden können, zufriedenstellend optimieren können. Die konkreten Problemstellungen sollen von der Praxis ausgehend in die Wissenschaft getragen werden. Dort soll eine Generalisierung des Problems vorgenommen werden, um darauf basierend Aussagen zur Anwendbarkeit tätigen zu können. Initial sollen bestehende Algorithmen angewendet werden. Problemgetrieben können Weiterentwicklungen dieser vorgenommen werden. Die Aussagen der Anwendbarkeit umfassen neben der binären Anwendbarkeit ("funktioniert", "funktioniert nicht") auch Empfehlungen für das Hyperparameter-tuning der Algorithmen und mögliche Grenzen durch problemspezifische Charakteristika (u.a. Dimensionalität).

Die Verfahren und Empfehlungen sollen nicht technisch-versierten Entscheidern durch Nutzung einer Transferplattform ("Optimization-as-a-Service") zur Verfügung gestellt werden.

### **Literatur**

Berkenkamp, Felix, Schoellig, Angela P., Krause, Andreas (2019). No-Regret Bayesian Optimization with Unknown Hyperparameters. *Journal of Machine Learning Research* 20-2019 S. 1-24.

Kochenderfer, Mykel J. und Wheeler, Tim A. (2019). *Algorithms for Optimization*. MIT Press.

B. Shahriari, K. Swersky, Z. Wang, R. P. Adams and N. de Freitas, "Taking the Human Out of the Loop: A Review of Bayesian Optimization," in *Proceedings of the IEEE*, vol. 104, no. 1, pp. 148-175, Jan. 2016, doi: 10.1109/JPROC.2015.2494218.