

## Kurzfassung

Durch die steigende Dynamisierung und Zunahme von disruptiven Ereignissen innerhalb der Liefernetzwerke von Unternehmen wird es zunehmend herausfordernder, Absatzbedarfe und deren Schwankungen innerhalb der Lieferkette ausreichend zu prognostizieren. Diese Unsicherheiten wirken sich direkt auf nachgelagerte Prozesse innerhalb der Supply Chain aus und führen zu ungenauen Planungsketten, da die Bedarfsplanung als taktische und strategische Planungsgröße verschiedene Planungsebenen bedingt. Um kurzfristige Änderungen und umweltbedingte Schwankungen in der Planung der Lieferkette zu berücksichtigen, ist es entscheidend, effiziente Prognosemodelle zu implementieren. Diese ermöglichen es Unternehmen, sich auf zukünftige Situationen frühzeitig vorzubereiten und entsprechende Planungen vorrausschauend anzupassen. Sowohl quantitative als auch qualitative Prognosemodelle sind jedoch aufgrund der zunehmenden Marktschwankungen und wechselnden Umfeldeinflüssen nicht bzw. nur bedingt geeignet, um eine Prognose in ausreichender Qualität zu erstellen. Um dennoch eine präzise Prognose zu erhalten, werden zunehmend Methoden des maschinellen Lernens oder des Deep Learning aus dem Bereich der künstlichen Intelligenz (KI) eingesetzt. Diese Prognosemodelle können Wechselwirkungen und Kausalzusammenhänge innerhalb der zur Verfügung stehenden Datenstrukturen erkennen und innerhalb des nächsten Prognosezyklus berücksichtigen. Die stetig kürzer werdenden Produktlebenszyklen erschweren jedoch die Bereitstellung der notwendigen Daten für die KI-basierte Bedarfsprognose.

In dem Spannungsfeld zwischen erhöhtem Datenbedarf und abnehmender Datenverfügbarkeit für die Bedarfsprognosen widmet sich die vorliegende Forschungsarbeit der Fragestellung, wie eine ausreichende Datengrundlage beim spezifischen Fall eines Produktanlaufs bereitgestellt werden kann, um bereits in den frühen Phasen des Produktlebenszyklus datenbasierte Prognosen mithilfe von KI-Methoden durchführen zu können. Dafür wird zuerst definiert, welche Anforderungen ein KI-basierter Ansatz an eine Datengrundlage stellt und welche Informationsquellen bei einer Produkteinführung zur Verfügung stehen. Zusätzlich wird eine Literaturrecherche zum Thema Bedarfsprognose bei Anlaufprodukten durchgeführt, um bereits bestehende Konzepte für z. B. statistische Ansätze aufzugreifen. Darauf aufbauend wird ein modulares phasenbasiertes Vorgehensmodell entworfen, das es ermöglicht, standardisiert Informationsquellen zu identifizieren und für das Training einer KI nutzbar zu machen. Das entwickelte Vorgehensmodell gliedert sich in fünf Module, die teilweise sequenziell, aber auch iterativ durchlaufen werden. Zuerst wird mithilfe einer Produkt- und Produktportfolioanalyse ein Grundverständnis des zu prognostizierenden Artikels geschaffen, um darauf aufbauend in Modul 2 systematisch mögliche Informationsquellen zu identifizieren. Im Modul 3 geht es anschließend um das Erstellen eines Trainingsdatensatzes, der sowohl die spezifischen Anforderungen der KI als auch die der Produktanlaufphase berücksichtigt. Modul 4 und 5 beschäftigen sich abschließend mit der eigentlichen Bedarfsprognose und der Integration von produktspezifischen Fehlerkurven, um die Prognosequalität weiter zu optimieren. Das entwickelte Vorgehensmodell und die genutzten Methoden werden abschließend anhand zweier Anwendungsbeispiele aus dem Bereich der Konsumgüterindustrie als Referenzbeispiele evaluiert, um den durch das Vorgehensmodell geschaffenen Mehrwert für KI-basierte Prognose im Kontext von Anlaufprodukten zu untersuchen.



---

## Summary

Due to increasing dynamic behavior and disrupting events within corporate supply chains it is becoming more and more challenging to predict sales demand and its fluctuations within the supply chain network. These uncertainties directly impact the following processes in the supply chain and lead to challenges within the integrated planning processes. Since especially the demand planning, being a tactical and strategical planning task, influences different planning levels.

In order to take into account short-term changes and environmental fluctuations in the planning of supply chains, it is essential to implement efficient demand forecasting models. These enable companies to prepare for future situations at an early stage and adjust their planning accordingly. However due to the increasing market fluctuations both quantitative and qualitative forecasting models are not suitable or only suitable to a limited extent to create a demand forecast of sufficient quality. Nevertheless, in order to get a precise forecast, methods of machine learning or deep learning from the field of artificial intelligence (AI) are being used increasingly. These forecasting models can detect interactions and causal relationships from the available data structures and incorporate these into the next forecast cycle. But the ever-shortening product lifecycles complicate providing the necessary data for AI based demand forecasting.

In this field of tension between increasing data requirements and decreasing availability of data for the demand forecasts this thesis focuses on how a valid data base can be generated for the case of new product launches. This data base serves as the requirement, to be able to carry out data based forecasting with methods of artificial intelligence in the early product lifecycle stages. The research work starts with the definition of the needed data base for a machine learning based forecasting model and the identification which information are available especially at the beginning of a product life cycle. In addition, a literature review is carried out on the topic of demand forecasting connected to the field of product launches to include existing concepts for generating an information basis for e.g. statistical approaches. Based on the results a modular and phase-based procedure model was created, which allows standardized identification of information sources which can be used for the training of an artificial intelligence. The developed procedure model is divided into five modules, which can sequentially and partially iteratively run through. First a product and product portfolio analysis is performed to create a basic understanding about the new product. The basic understanding is the foundation for the identification of possible information sources within the product portfolio, which is described in module two. In the following module three the data set for training is being generated considering the specific requirements of a machine learning method and the use case of a product launch. Modul four and five lastly cover the AI based demand forecasting and the integration of error adaptations and curves, to further optimize the final forecast quality based on the first error feedback information. Thereafter the developed procedure model and the used methods are being evaluated on the basis of two use cases from the consumer goods sector as reference examples. The evaluation focuses on the estimation of the added value which is generated on the basis of the procedure model for the use of machine learning based demand forecasting in the context of product launches.