

Vorhersage von Aufträgen eines Logistikdienstleisters mit Hilfe statistischer Modelle, Machine Learning und neuronalen Netzen

Lina Marie Müller

Prof. Dr. Harald Ritz

Manuel Groh (M.Sc.)

Mathematik, Naturwissenschaften
und Informatik
Wiesenstraße 14
35390 Gießen
E-Mail:
lina.marie.mueller@mni.thm.de

Mathematik, Naturwissenschaften
und Informatik
Wiesenstraße 14
35390 Gießen
E-Mail:
harald.ritz@mni.thm.de

Mathematik, Naturwissenschaften
und Informatik
Wiesenstraße 14
35390 Gießen
E-Mail:
manuel.groh@mni.thm.de

Kategorie

Abschlussarbeit

Schlüsselwörter

Auftragsprognose, KI, Logistik, Machine Learning, Neuronale Netze, Statistik, Zeitreihenprognose

Zusammenfassung

Diese Thesis beschäftigt sich mit der Entwicklung einer Auftragsprognose für einen Logistikdienstleister in der Distributionslogistik. Da die Profitabilität des Unternehmens maßgeblich von der effizienten Abwicklung der logistischen Prozesse abhängt, ist es wichtig, verlässliche Informationen über zukünftige Aufträge vorliegen zu haben, um sich auf diese vorzubereiten und sie effizient abzuwickeln. Auf Basis von Auftragsprognosen können beispielsweise die Personaleinsatzplanung und die Lagerhaltung optimiert werden. Es sollen Prognosen über die Anzahl und Höhe der Aufträge sowohl für einzelne Kostenstellen als auch für alle Kostenstellen zusammen entwickelt werden.

Die Auftragsprognose kann in den Kontext der Zeitreihenprognose gestellt werden, bei der auf Basis einer historischen, zeitlich erhobenen Datenreihe eine Prognosefunktion gefunden werden soll, mit der zukünftige Werte berechnet werden können. Konkret handelt es sich hier um eine Multi-Step-Ahead-Prognose mit einem Prognosehorizont von 90 Tagen bei täglicher Frequenz.

Um die ideale Lösung für den Anwendungskontext zu finden wurden zunächst Bewertungskriterien definiert. Diese sind die Genauigkeit, die Erklärbarkeit der Prognose, die Fähigkeit probabilistische Prognosen zu erstellen und die Rechenzeit. Dabei wird die Genauigkeit am stärksten gewichtet und anhand verschiedener Metriken (RMSE, MASE, MAE, Bias) bewertet. Für den Vergleich wurden aus der vorhandenen Datenbasis die benötigten Zeitreihen erzeugt, eine Version der Datenbasis mit entfernten Ausreißern erstellt und verschiedene Merkmale für die Einbeziehung in die

Prognose aufbereitet. Dabei handelt es sich um Kalendermerkmale und Wetterdaten.

Die verglichenen Modelle umfassen die exponentielle Glättung und Croston als Vertreter der statistischen Modelle, die lineare Regression und XGBoost als Vertreter der maschinellen Lernmodelle und N-BEATS und TFT (Temporal Fusion Transformer) als neuronale Netzarchitekturen. Für jede Modellklasse wurden die optimalen Hyperparameter für Anzahl und Höhe der Aufträge bestimmt und diese Lösung anschließend anhand der Bewertungskriterien bewertet.

Die exponentielle Glättung erwies sich als das beste Modell für die Anzahl der Aufträge für einzelne Kostenstellen und für alle Kostenstellen zusammen. Der Nachteil der exponentiellen Glättung war, dass keine probabilistischen Vorhersagen getroffen werden konnten. Für die Höhe der Aufträge konnten sich hingegen die maschinellen Lernmodelle durchsetzen. Für einzelne Kostenstellen war die lineare Regression die ideale Lösung und konnte für alle Bewertungskriterien gute Ergebnisse erzielen. Für die Prognose aller Kostenstellen zusammen konnte XGBoost die besten Ergebnisse mit hoher Genauigkeit und Interpretierbarkeit erzielen. Die Überlegenheit der maschinellen Lernmodelle gegenüber den statistischen Modellen kann damit zusammenhängen, dass die Zeitreihen für die Auftragshöhe unregelmäßiger waren, als die für die Auftragsanzahl und somit von der höheren Modellkomplexität und der Möglichkeit der Einbeziehung externer Variablen profitieren konnten.

Generell zeichneten sich die statistischen Modelle jedoch insbesondere bei der exponentiellen Glättung durch hohe Genauigkeit, kurze Rechenzeit und gute Erklärbarkeit aus. Das Potenzial der maschinellen Lernmodelle und der neuronalen Netze, externe Variablen in die Prognose einzubeziehen, konnte hier nicht ausgeschöpft werden, da nur wenige Zusatzinformationen zur Verfügung

standen. Wenn Informationen insbesondere über interne Faktoren vorliegen, z.B. geplante Marketing- oder Rabattaktionen, können maschinelle Lernmodelle und neuronale Netze einen großen Vorteil gegenüber den statistischen Modellen haben.

Auch wenn die neuronalen Netze im Anwendungskontext schlechter abschnitten, konnte die Temporal-Fusion-Transformer-Architektur Potential zeigen, indem sie als einziges Modell Abweichungen von ansonsten gleichförmigen Mustern vorhersagte und sich zudem durch ihre Interpretierbarkeit auszeichnete.

Um die Ergebnisse der ausgewählten Modelle weiter zu verbessern, kann die Datenvorbereitung an die Modelle angepasst werden, da diese aus Gründen der Vergleichbarkeit allgemein gehalten wurde. Darüber hinaus kann eine weitergehende Hyperparameteroptimierung durchgeführt werden und Möglichkeiten zur Erstellung von probabilistischen Vorhersagen mit exponentieller Glättung evaluiert werden.

Bei der Einführung der Prognosemodelle in den produktiven Betrieb ist darauf zu achten, dass die Prognosen richtig interpretiert werden. Es handelt sich nicht um perfekte Prognosen und es sollte immer die Möglichkeit von Abweichungen von den Prognosen berücksichtigt werden. Ein grundlegendes Verständnis der verwendeten Modelle kann bei der richtigen Interpretation hilfreich sein. Nach der Einführung der Prognose sollte evaluiert werden, ob sie im Produktivbetrieb einen Mehrwert bietet und darauf aufbauende Anwendungen, z.B. in der Personaleinsatzplanung, entwickelt werden.

Literatur

Axsäter, Sven, Inventory Control. Springer New York, 2006, Vol. 2. [Online]. URL: <http://dx.doi.org/10.1007/0-387-33331-2>

Chen, Tianqi und Guestrin, Carlos, „XGBoost: A Scalable Tree Boosting System,” in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Serie KDD '16. ACM, Aug. 2016. [Online]. URL: <http://dx.doi.org/10.1145/2939672.2939785>

Lim, Bryan, Arik, Sercan O., Loeff, Nicolas, und Pfister, Tomas, „Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting,” 2019. [Online]. URL: <https://arxiv.org/pdf/1912.09363.pdf>

Oreshkin, Boris N., Carpov, Dmitri, Chapados, Nicolas, und Bengio, Yoshua, „N-BEATS: Neural basis expansion analysis for interpretable time series forecasting,” in International Conference on Learning Representations, 2020. [Online]. URL: <https://openreview.net/forum?id=r1ecqn4YwB>

Petropoulos, Fotios et al., „Forecasting: theory and practice,” International Journal of Forecasting, Vol. 38, Nr. 3, S. 705–871, 2022. [Online]. URL: <http://dx.doi.org/10.1016/j.ijforecast.2021.11.001>

Spiliotis, Evangelos, „Time Series Forecasting with Statistical, Machine Learning, and Deep Learning Methods: Past, Present, and Future,” in Forecasting with Artificial Intelligence. Springer Nature Switzerland, 2023, S. 49–75. [Online]. URL: http://dx.doi.org/10.1007/978-3-031-35879-1_3

Vandeput, Nicolas, Data Science for Supply Chain Forecasting. De Gruyter, 2021. [Online]. URL: <http://dx.doi.org/10.1515/9783110671124>

Vogel, Jürgen, Prognose von Zeitreihen: Eine Einführung für Wirtschaftswissenschaftler. Springer Fachmedien Wiesbaden, 2015. [Online]. URL: <http://dx.doi.org/10.1007/978-3-658-06837-0>