Neural Networks in Time Series Forecasting: Architectures, Evaluation, and Uncertainty Quantification for Macroeconomics and Commodity Prices

Ausgangslage

Wie viele Rohstoffpreise sind auch Stahlpreise extremen Schwankungen unterworfen, was die Planungssicherheit in der gesamten Lieferkette und insbesondere im Großhandel gefährdet. Damit Stahlgroßhändler trotzdem wirtschaftlich agieren können, ist eine gute Preiseinschätzung entscheidend, wobei diese von vielen Faktoren und deren Gewichtung abhängt. Bisher versuchen Einkaufende diese Entwicklung intuitiv vorherzusagen. Durch die Globalisierung wird dies jedoch immer komplexer, was fundierte Preiseinschätzungen und gute Einkaufsentscheidungen erschwert. Existierende Prognosen betrachten häufig nur monatliche Werte, was nicht der täglichen und wöchentlichen Entscheidungsfrequenz im Großhandel entspricht. Zudem sind sie nicht auf Genauigkeit evaluiert und liefern keine Unsicherheitsabschätzung oder einen Nachweis der tatsächlichen Kostenreduktion in der Beschaffung. Bei Rohstoffpreisen mit hoher Unsicherheit ist dies aber besonders wichtig, da falsche Entscheidungen sehr teuer sein können.

Fragestellung

Die Dissertation untersucht, ob Stahlpreise prognostizierbar sind, um Großhändlern Einsparpotenziale in der Beschaffung zu ermöglichen. Im Mittelpunkt stehen drei weitere Fragen:

- Wie können angepasste neuronale Netze für Rohstoffpreisprognosen implementiert und frei verfügbar in die Anwendung gebracht werden?
- Wie müssen Stahlpreisprognosen aufbereitet sein, damit Einkaufende ohne KI-Hintergrund die Ergebnisse nachvollziehen und bestmöglich nutzen können?
- Wie kann die prognostizierte Unsicherheit effizient berechnet und informativ dargestellt werden?

Kapitelübersicht

In Kapitel 1 der Dissertation wurden „Historical Consistent Neural Networks“ (HCNNs) (Zimmermann, et al., 2011), Unsicherheits-Heatmaps (Köpp, et al., 2014) und Sensitivitätsanalysen für Rohstoffpreisprognosen erstmals in der Open-Source Software ProsperNN implementiert (Beck, et al., 2024-a) und auf GitHub bereitgestellt. HCNNs sind besonders an Rohstoffpreisprognosen mit häufig kurzen Datenhistorien angepasst und die genannten Analyse-Methoden erhöhen die Interpretierbarkeit und die Akzeptanz bei Einkaufenden. Dadurch lassen sich Rohstoffpreisprognosen im Großhandel leichter erstellen. Darüber hinaus haben bisherige Studien für schwer prognostizierbare Zeitreihen aus dem Bereich des maschinellen Lernens kaum untersucht, ob moderne Prognosemodelle naiven

Prognosen (konstante Prognose des letzten bekannten Wertes) überlegen sind. In Kapitel 2 werden zahlreiche Prognosemodelle auf Wechsel- und Aktienkursen getestet (Beck, et al., 2025). Dabei wird betont, wie wichtig ein Vergleich mit der naiven Prognose ist, was Modelle in der Anwendung verhindert, die schlechter als die naive Prognose sind.
Im Rahmen eines Industrieprojekts mit einer Gruppe von Stahlgroßhändlern wurde ein Datensatz zur Prognose von Stabstahl, Betonstahl, Warmbreitband und Edelstahl inklusive deren wichtigster Einflussgrößen erstellt. Mit Hilfe einer Sensitivitätsanalyse wird die Relevanz der Einflussgrößen quantifiziert und iterativ geschärft. Im Projekt wird monatlich eine Prognose für die nächsten 20 Wochen erstellt, damit die Händler kurz- und langfristige Entscheidungen treffen können. Dabei werden die Prognosen mit Unsicherheits-Heatmaps detailliert analysiert. Im Gegensatz zu Punktprognosen können diese mehrere Zukunftsszenarien darstellen (siehe Abb. 1). Dies ist für die Preisentwicklung realistischer, da sie eine hohe Unsicherheit aufweist.
Kapitel 3 bewertet die Genauigkeit von Stahlpreisprognosen (Beck, et al., 2024-b). Hierfür konnte der Fehler mit HCNNs im Vergleich zu Vergleichsmethoden signifikant reduziert werden. Um eine tatsächliche Kostenreduktion für den Großhandel in der Beschaffung nachzuweisen, wird in der Dissertation erstmals eine Beschaffungssimulation entwickelt. Die auf HCNN-Prognosen basierende Simulation zeigt abhängig von der Stahlsorte eine Kostenreduktion zwischen 0,6 % und 2,7 % im Vergleich zu einer Just-in-time-Beschaffung.
Bei makroökonomischen Prognosen aus dem Bereich des maschinellen Lernens wird außerdem meist keine Prognoseunsicherheit geschätzt. In anderen Anwendungen werden häufig ressourcenintensiv mehrerer Prognoseszenarien mit einem Ensemble erstellt und deren Streuung als Unsicherheit interpretiert (Lakshminarayanan, et al., 2017). Um Unsicherheiten effizienter darzustellen, approximiert Kapitel 4 diese Methode schrittweise durch eine Reduktion der Modell-Parameter. Die Unsicherheitsdarstellung wird dadurch deutlich effizienter mit fast gleichwertiger Genauigkeit.

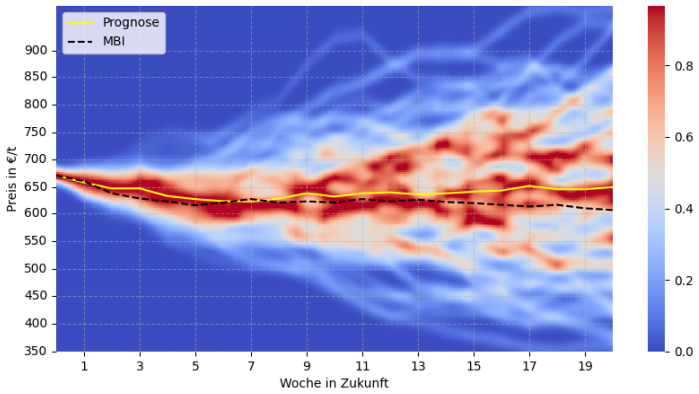


Abb. 1 Unsicherheits-Heatmap: Dunkelrote Bereiche deuten auf einen wahrscheinlicheren Ausgang hin

Relevanz für den Großhandel

Der Großhandel hat ein hohes Handelsvolumen bei gleichzeitig niedrigen Gewinnmargen. Dadurch haben bereits kleine prozentuale Ersparnisse beim Einkauf einen großen Hebel, der sich direkt in einem höheren Gewinn niederschlägt. Mit Hilfe der Stahlpreisprognose können die Großhändler ihre Einkaufspreise reduzieren, indem sie ihre Einkaufszeitpunkte optimieren. Zusätzlich sollen extreme Preisschwankungen frühzeitig erkannt werden, um die Planungs- und Versorgungssicherheit durch vorausschauende Lagerhaltung zu verbessern und damit die finanziellen Risiken zu verringern.
Anstatt sich nur auf die Genauigkeit der Prognosen zu konzentrieren, baut die Dissertation eine Brücke zum tatsächlichen Nutzen der Großhändler. So bewertet sie die Kostenreduktion in der Beschaffung und unterstützt die Einkaufenden bei den hochriskanten Entscheidungen.
Die entwickelte Methodik ist grundsätzlich auf viele Branchen (z. B. Metalle, Chemikalien, Energie) übertragbar. Bei vorsichtiger Schätzung ist eine frühzeitige Antizipierung von Rohstoffpreisen für mehr als 25 % der rund 140.000 Großhändler in Deutschland von Bedeutung. Die Arbeit zeigt, dass Stahlpreisprognosen im Großhandel den Einkaufspreis reduzieren können. Dabei legt sie ein Fundament für Rohstoffpreisprognosen und eröffnet damit Forschungspotenzial, um den Mehrwert für den Großhandel aufbauend auf der Dissertation weiter zu steigern.

Danksagung

Ich bedanke mich herzlich bei der ForveG für die Verleihung des Forschungspreises. Die Auszeichnung bedeutet mir sehr viel und erfüllt mich mit großer Dankbarkeit. Mein besonderer Dank gilt den Sponsoren, der KNAPP Deutschland AG und der Oskar Böttcher GmbH & Co. KG, für deren großzügige Unterstützung des Forschungspreises. Des Weiteren danke ich dem Projektteam der Stahlpreisprognose sowie meinen Co-Autorinnen und Co-Autoren am Fraunhofer IIS für die konstruktive Zusammenarbeit und den wertvollen wissenschaftlichen Austausch. Ganz besonderen Dank schulde ich meinen Dissertationsbetreuern, Herrn Prof. Dr. Jonas Dovern und Frau Prof. Dr. Stefanie Vogl, deren fachliche Betreuung diese Arbeit maßgeblich vorangetrieben hat.

Literaturverzeichnis

Beck, N., Dovern, J. & Vogl, S., 2025. Mind the naive forecast! a rigorous evaluation of forecasting models for time series with low predictability. *Applied Intelligence,* 55(6), p. 395.

Beck, N. et al., 2024-b. Historical Consistent Neural Networks for Steel Price Forecasting. *SSRN: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=6459160.*

Beck, N. et al., 2024-a. Introducing ProsperNN—a Python package for forecasting with neural networks. *PeerJ Computer Science,* Band 10.

Köpp, C., von Mettenheim, H.-J. & Breitner, M. H., 2014. Decision Analytics with Heatmap Visualization for Multi-step Ensemble Data. *Business & Information Systems Engineering,* Band 6.3, pp. 131-140.

Lakshminarayanan, B., Pritzel, A. & Blundell, C., 2017. Simple and Scalable Predictive Uncertainty Estimation using Deep Ensembles. *Advances in Neural Information Processing,* Band 30.

Zimmermann, H., Grothmann, R., Tietz, C. & Jouanne-Diedrich, H., 2011. Market Modeling, Forecasting and Risk Analysis with Historical Consistent Neural Networks. In: *Operations research proceedings 2010.* s.l.:Springer, pp. 531-536.