

Wechselkursenprognosen mit Methoden der künstlichen Intelligenz

Bachelorarbeit

zur Erlangung des akademischen Grades „Bachelor of Science (B.Sc.)“ im
Studiengang Wirtschaftswissenschaft der Wirtschaftswissenschaftlichen Fakultät
der Leibniz Universität Hannover

vorgelegt von:

Name:

Sentürk

Vorname:

Serkan



Prüfer:

Prof. Dr. Hans-Jörg von Mettenheim

Ort, Datum:

Hannover, den 10.02.2017

Inhaltsverzeichnis

Abkürzungsverzeichnis	IV
Abbildungsverzeichnis	V
Tabellenverzeichnis.....	VI
1. Einleitung	1
1.1 Motivation	1
1.2 Aufbau der Arbeit.....	1
1.3 Recherchestatus	1
2. Wechselkurse und damit verbundene Finanzdaten	2
2.1 EUR/USD Wechselkurs	3
2.2 Transformation in Reihe von Renditen	5
2.3 Inputdaten der Neuronalen Netze	7
3. Prognosemodelle	8
3.1 Benchmark Prognosemodelle.....	8
3.1.1 Naive Strategie	8
3.1.2 Auto-Regressive Moving Average Modell.....	9
3.2 Neuronale Netze	10
3.2.1 Das Multi-Layer Perceptron Modell	11
3.2.2 Das Rekurrente Neuronale Netz.....	13
3.2.3 Das Psi-Sigma Neuronale Netz	14
4. Messung der Performance	16
4.1 Statistische Performance	16
4.2 Trading-Performance.....	18
4.2.1 Trading Strategie und Transaktionskosten	18
4.2.2 Trading-Performance ohne Hebel	19
5. Prognosekombinationen	21
5.1 Kombinationsmodelle	22
5.1.1 Einfacher Durchschnitt.....	22
5.1.2 Bayesian Averaging	22

5.1.3 Least Absolute Shrinkage and Selection Operator (LASSO).....	23
5.1.4 Kalman Filter.....	24
5.2 Statistische Performance der Prognosekombinationen.....	25
5.3 Trading-Performance der Prognosekombinationen.....	26
6. Fazit und Ausblick	29
Anhang	VIII
Literaturverzeichnis.....	XI
Ehrenwörtliche Erklärung	XII

1. Einleitung

1.1 Motivation

Heute die Information zu haben, wie sich der Wechselkurs zum nächsten Handelstag verändern wird, hat viele Vorteile. Privatanleger, Banken und Unternehmen können von diesem Wissen profitieren, indem sie frühestmöglich entsprechend auf diese Veränderung reagieren, somit lassen sich hohe Gewinne generieren. Nun geht es darum die genaueste Prognose zu erstellen. In dieser Arbeit wird die Trading-Performance verschiedener Neuronaler Netze untersucht und traditionellen Prognosemodellen gegenübergestellt. Ferner kommen statistische Modelle zum Einsatz, welche die Prognosen der Neuronalen Netze kombinieren und folglich die Trading-Performance erhöhen sollen.

1.2 Aufbau der Arbeit

Zunächst wird in Kapitel 2 der Wechselkurs in eine Reihe von Rendite transformiert. Dieser Vorgang bildet die Basis für das weitere Vorgehen. Nun wenden wir diese auf eine Naive Strategie, ein Autoregressive Moving Average Modell und drei Neuronale Netze an. Diese sind das Multi-Layer Perceptron, das Rekurrente Neuronale Netz und das Psi-Sigma Neuronale Netz. In Kapitel 5 werden die Prognosen der Neuronalen Netze miteinander kombiniert und evaluiert. Zum Schluss erfolgt in Kapitel 6 ein Fazit über die verwendeten Modelle und ein Vergleich mit den Ergebnissen von Sermpinis et al. aus dem Jahr 2012.

1.3 Recherchestatus

Diese Arbeit orientiert sich stark an dem Paper „Forecasting and trading the EUR/USD exchange rate with stochastic Neural Network combination and time-varying leverage“ von G. Sermpinis, C. Dunis, J. Laws und C. Stasinakis aus dem Jahr 2012. Dieses Paper deckt bereits einen Großteil der

benötigen Informationen ab. Als ergänzende Informationen und zum besseren Verständnis, besonders im Bereich der statistischen Modelle, wurden verschiedene Lehrbücher benutzt. Die Suche nach Informationen bezüglich der praktischen Umsetzung, verschiedenster Modelle, erwies sich hingegen als äußerst schwierig. Sämtliche Dateien, die in dieser Arbeit verwendet wurden, befinden sich auf der beiliegenden CD-ROM.

2. Wechselkurse und damit verbundene Finanzdaten

Die Zentralbanken der Eurozone sowie Zentralbanken die sich außerhalb der Eurozone befinden, ermitteln einmal am Tag im Rahmen eines Konzertationsverfahrens zwischen den Zentralbanken die Referenzkurse. In der Regel findet dieses Verfahren um 14:15 Uhr¹ statt. Die Referenzkurse sind die rechnerischen Durchschnittskurse, auf Basis der Geld- und Briefkurse. Der Mittelkurs wird nicht in Geld- oder Briefnotierung, sondern lediglich in Mengennotierung² veröffentlicht. Die Publizierung erfolgt durch die Europäische Zentralbank (EZB) zwischen 14:30 Uhr bis 15:00 Uhr über die üblichen Informationsmedien.³

In dieser Arbeit wird der EUR/USD Wechselkurs im Zeitraum der Jahre 2011 bis 2016 untersucht. In Tabelle 1 wird die Aufteilung der Datensätze in verschiedene Kategorien veranschaulicht. Die Aufteilung in In-Sample sowie Out-of-Sample ist notwendig um die Neuronalen Netze (NNs) zu trainieren.⁴

TABELLE 1: ÜBERSICHT DER EUR/USD DATENSÄTZE⁵

Zeitabschnitte	Handelstage	Anfangsdatum	Enddatum
Gesamter Datensatz	1536	03.01.2011	31.12.2016

¹ EZB Zeit, Mitteleuropäische Zeit.

² Einheiten in Fremdwährung für 1 Euro. Z.B. 1 Euro = 0,92 US Dollar.

³ Vgl. Eller (2002), S. 192

⁴ Sermpinis et al. (2012), S. 317

⁵ In Anlehnung an ebd. S. 318

6. Fazit und Ausblick

In dieser Arbeit untersuchen wir die Trading-Performance und die statistische Performance von verschiedenen Prognosemodellen sowie den Nutzen verschiedener Kombinationsmodelle, welche auf die Prognosen der NNs angewendet werden. Zuerst wenden wir die EUR/USD Zeitreihe auf die Naive Strategie und auf ein ARMA Modell an, welche als Benchmark fungieren. Wir erweitern diese Anwendung auf die NNs, bestehend aus einem MLP, einem RNN und einem PSN. Anschließend werden die Prognosen der NN miteinander kombiniert. Hierfür werden vier Kombinationsmodelle benutzt. Diese sind: der einfache Durchschnitt, Bayesian Averaging, Least Absolute Shrinkage and Selection Operator (LASSO) und das Kalman Filter. Die Grundlage der Prognosen bilden die EUR/USD Referenzkurse aus den Jahren 2011-2016 der Europäischen Zentralbank (EZB), wobei der Zeitraum vom 01.07.2015 bis zum 31.12.2016 als Out-of-Sample Test dient. Für diesen Zeitraum wird die beste individuelle Trading-Performance durch das RNN erzielt. Betrachtet man nun die Prognosekombinationen der verschiedenen Modelle, fällt auf, dass, gemessen an der Trading-Performance, jede Kombination bessere Ergebnisse erzielt als die beste individuelle Prognose. Das Bayesian Averaging Modell ist hierbei führend. Es erzielt, unter Betrachtung sämtlicher Modelle, mit 10,31% die höchste jährliche Rendite und erreicht außerdem mit -6,5% den besten Maximum Drawdown Wert. Mit einer Information Ratio von 1,09 besteht weiterhin die Möglichkeit, durch Hebel die Performance zu Verbessern. Vergleicht man die Ergebnisse mit denen von G. Sermpinis, C. Dunis, J. Laws und C. Stasinakis aus dem Paper „Forecasting and trading the EUR/USD exchange rate with stochastic Neural Network combination and time-varying leverage“ von 2012, fällt die vergleichsweise schlechte Performance (statistische Performance als auch Trading-Performance) des Kalman Filters auf. Dieser erzielte in dem Paper von Sermpinis et al. in jeder Hinsicht die beste Performance, wohingegen er in dieser Arbeit die schlechteste Trading-Performance aller Prognosekombinationen erzielt. Dies ist zurückzuführen auf die Daten, welche für diese Arbeit von Sermpinis et al. übernommen wurden. Diese sind konzipiert für den Zeitraum 2002-2010 und somit für selbigen optimal. Damit das Kalman Filter die Performance verbessern kann, sind weitere Anpassungen notwendig. Die schlechte statistische Performance des Kalman Filters in dieser Arbeit bestätigt dies. Grundsätzlich ist zu erkennen, dass die Prognosekombinationen sinnvoll sind, sofern eine gute statistische Performance erzielt wird. Ein möglicher Ansatz um die Performance zu verbessern, ist die Erweiterung des Datensatzes, welcher in dieser Arbeit einen Umfang von 1536 Handelstagen umfasst. Mit einer größeren Anzahl an Daten ist es möglich, den Trainingsprozess der NNs zu optimieren und folglich genauere

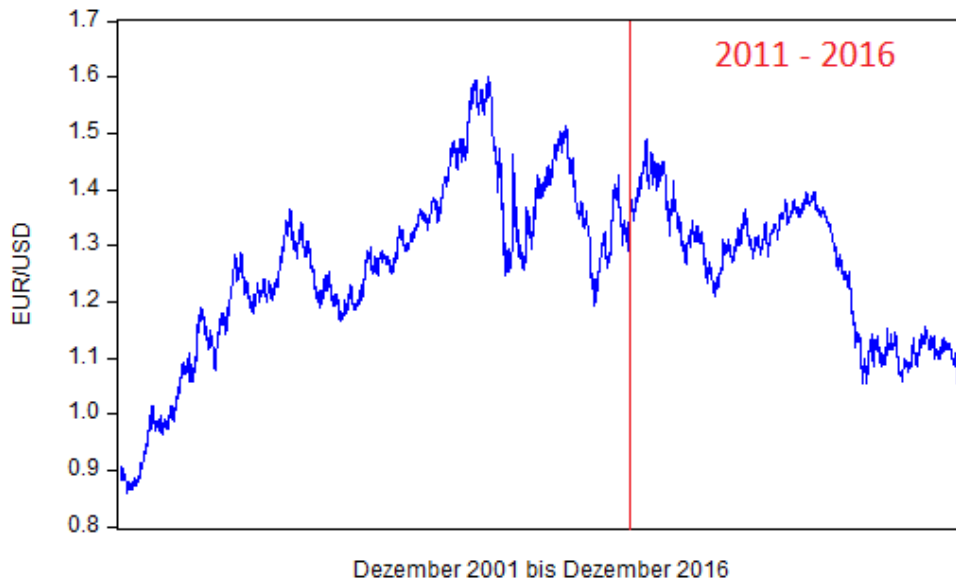


ABBILDUNG 11: EUR/USD WECHSELKURS 2001-2016

Prognosen zu erzielen. Betrachtet man den EUR/USD Wechselkurs der Jahre 2001 bis 2016 in Abbildung 11, so ist festzustellen, dass in der betrachteten Periode dieser Arbeit der Wechselkurs stark gefallen ist. Diese Entwicklung trägt dazu bei, dass die individuellen Prognosen sowie die Prognosekombinationen im Vergleich mit Sermpinis et al., eine schlechtere Performance erzielen.

Abschließend ist festzustellen, dass die Resultate dieser Arbeit die Nutzung von NNs zur Prognose von Wechselkursen, als auch die Anwendung verschiedener Modelle zur Kombination dieser Prognosen, unterstützen.