

Forecasting in Finance and Macroeconomics

Der Lehrstuhl für Angewandte Statistik betreut im Sommersemester Seminararbeiten an der Schnittstelle zwischen Statistik und Makroökonomie sowie Finance mit einem Schwerpunkt auf der Prognose von Zeitreihen mit der Open-Source Programmiersprache R. Als Hauptliteratur wird das über die Bücherei der FernUniversität in Hagen online verfügbare Lehrbuch von Ghysels und Marcellino (2018) verwendet. Diese Hauptquelle wird durch themenspezifische Fachliteratur ergänzt. Im Rahmen der empirischen Analyse sollen Daten mit der Programmiersprache R analysiert werden. Hierzu werden im Laufe des Seminars Online-Tutorien angeboten. Darüber hinaus wird über die Universitätsbibliothek eine Schulung zum Thema Informationskompetenz und Literaturrecherche Wirtschaftswissenschaft mit dem Schwerpunkt Angewandte Statistik angeboten.

In dem Seminar werden 16 Oberthemen jeweils doppelt vergeben (mit angepasster Forschungsfrage).

- **Value at Risk (VaR)**

Finanzinstitute wie Banken und Versicherungen sind rechtlich verpflichtet, ihr eingegangenes Risiko am Finanzmarkt zu messen (u.a. Basel III, Solvency II). Ein mögliches Werkzeug stellt dabei das Risikomaß Value at Risk (VaR) dar. Dieses gibt an, welcher Verlust innerhalb eines bestimmten Zeitraums mit einer bestimmten Wahrscheinlichkeit nicht überschritten wird. Ziel dieser Seminararbeit ist es, verschiedene Verfahren zur Schätzung und Prognose des VaRs darzustellen und schlussendlich auf Aktienkurse ausgewählter Dow Jones Unternehmen bzw. Kryptowährungen anzuwenden.

Einstiegsliteratur: J.P.Morgan und Reuters (1996), Kuester et al. (2006), Christoffersen (2012), McNeil et al. (2015) und Ghysels und Marcellino (2018)

- **GARCH Modelle zur Prognose von Rohstoffmarktschwankungen**

Seit geraumer Zeit ist bekannt, dass es in Finanzzeitreihen wie Aktien- oder Goldrenditen zu sog. Volatilitätsclustern kommt. Dabei folgen auf Zeiten hoher Volatilität tendenziell Zeiten hoher Volatilität auf auf Zeiten niedriger Volatilität Zeiten niedriger Volatilität. Da die Volatilität als ein Risikoindikator angesehen wird, wollen Finanzakteure diese natürlich prognostizieren. Ein mögliches Werkzeug stellen dabei Generalized Autoregressive Conditional Heteroskedasticity (GARCH) Modelle dar. Ziel dieser Seminararbeit ist es, die Volatilität der Renditen der beiden Edelmetalle Gold und Silber bzw. der beiden Ölsorten Brent und WTI vorherzusagen.

Einstiegsliteratur: Bollerslev (1986), Lundbergh und Teräsvirta (2002), Christoffersen und Jacobs (2004), McNeil et al. (2015) und Ghysels und Marcel-

lino (2018)

- **Realized Volatility - HAR Modell**

Neben dem GARCH Modell hat sich das Konzept der Realized Volatility zur Berechnung der Volatilität auf Finanzmärkten etabliert. Im Gegensatz zum GARCH Modell wird Realized Volatility of Basis ultra-hochfrequenter (intraday) Daten nichtparametrisch berechnet. Eine elegante Möglichkeit zur Vorhersage der Realized Volatility stellt das Heterogeneous Autoregression (HAR) Modell dar. Ziel dieser Seminararbeit ist es, das HAR Modell auf ausgewählte Aktienindizes anzuwenden, um die Realized Volatility vorherzusagen.

Einstiegsliteratur: Andersen et al. (2001), Andersen et al. (2003), McAleer und Medeiros (2008), Corsi (2009), Ghysels und Marcellino (2018) und Clements und Preve (2021)

- **LASSO für die Renditeprognose**

Um eine zu hohe Anzahl an Parametern in Regressionsmodellen zu vermeiden, können Bestrafungsterme eingeführt werden. Gerade im Asset Pricing, wo es eine Vielzahl an möglichen Faktoren gibt, kann ein Least Absolute Shrinkage and Selection (LASSO) Ansatz dazu beitragen, die Modellgröße erheblich zu verkleinern und den Prognosefehler zu reduzieren. Ziel dieser Seminararbeit ist es, die Rendite von Öl bzw. des Immobilienmarktes mit Hilfe des LASSO-Ansatzes zu prognostizieren.

Einstiegsliteratur: Tibshirani (1996), Hastie et al. (2008), Ghysels und Marcellino (2018), Zhang et al. (2019) und Gu et al. (2020)

- **Kointegrationsanalyse von Aktienpreisen und Dividenden**

Zur Bewertung von Aktien wird häufig eine Art von Dividendendiskontierungsmodell verwendet. Dabei ist die Idee dahinter, dass sich der Wert einer Aktie anhand der zukünftigen erzielbaren Dividenden abgezinst auf den heutigen Tag ergibt. Dabei wird von verschiedenen Forschern darauf hingewiesen, dass es ein langfristiges Gleichgewicht zwischen Aktienpreisen und deren Dividenden gibt. Ziel dieser Seminararbeit ist es, Unternehmen des amerikanischen bzw. britischen Finanzmarktes hinsichtlich Kointegration von deren Aktienpreis und Dividende zu untersuchen.

Einstiegsliteratur: Campbell und Shiller (1987), Campbell und Shiller (1988), Cerchi und Havenner (1988), Koop (1991) und Ghysels und Marcellino (2018)

- **Nichtlineare Modelle - TAR zur Wechselkursprognose**

In vielen ökonomischen und finanzwirtschaftlichen Situationen hat sich herausgestellt, dass Zusammenhänge häufig nicht linear sind, sondern kom-

plexere Beziehungen aufweisen. Um diese zu erfassen, wurden Modelle wie Threshold Autoregressive (TAR) entwickelt. Hierbei wird der Beobachtung Rechnung getragen, dass sich Abhängigkeiten zwischen ökonomischen Variablen häufig ändern, wenn bestimmte Schwellwerte (Thresholds) überschritten worden sind. Ziel dieser Seminararbeit ist die Prognose von Wechselkursen mittels Threshold Modellen.

Einstiegsliteratur: Chan und Tong (1986), Dijk et al. (2002), Elliott et al. (2006), Rapach und Wohar (2006) und Ghysels und Marcellino (2018)

- **Gemischte Frequenzen - MIDAS für die Dividendenprognose**

Häufig kommt es im Finance-Bereich vor, dass man nicht alle Kennzahlen/Variablen für jede Frequenz zur Verfügung hat. So liegen Aktienpreise z.B. handelstäglich vor, während Dividenden je nach Land nur quartalsweise, halbjährlich oder jährlich gezahlt werden. Ziel dieser Seminararbeit ist die Prognose der Dividende von ausgewählten Unternehmen mit Hilfe von Daten, die eine höhere Frequenz aufweisen.

Einstiegsliteratur: Ghysels, Santa-Clara et al. (2004), Marcellino und Schumacher (2010), Ghysels und Marcellino (2018) und Wang et al. (2020), Ghysels et al. (2007)

- **Faktorenanalyse - Hauptkomponentenanalyse für Aktienportfolios**

Eine andere Möglichkeit zur Reduzierung der Anzahl der Faktoren in einem Modell (im Vergleich zum LASSO) ist die Anwendung der Hauptkomponentenanalyse. So kann diese z.B. angewendet werden, um die Kovarianzmatrix eines großen Portfolios mit Hilfe weniger Faktoren zu erklären. Der Vorteil hierin besteht darin, die Berechnungsdauer zu verkürzen. Ziel dieser Seminararbeit ist die Anwendung der Hauptkomponentenanalyse auf die Unternehmen des DAX 40 bzw. des AEX und deren Kovarianzmatrix zu schätzen.

Einstiegsliteratur: Tsay (2010), McNeil et al. (2015), Ghysels und Marcellino (2018), Kozak et al. (2018) und Giglio und Xiu (2021)

- **Prognoseevaluation und Prognosekombination**

Liegen Prognosen verschiedener Modelle vor, so stellt sich die Frage nach der Vergleichbarkeit, sowie die Frage, welche Prognosen besser abschneiden, um Rückschlüsse auf die Prognosequalität einzelner Modelle zu schließen. Hierfür können verschiedene Maße (z.B. MAE, MSE oder auch RMSE) zur Berechnung der Prognosegüte verglichen werden, sowie der Diebold-Mariano Test präsentiert werden. Nach dem Vergleich verschiedener Prognosemodelle, besteht außerdem die Möglichkeit Prognosen zu kombinieren, um den Prognosefehler weiter zu reduzieren. Hierbei spielt insbesondere die Gewichtung einzelner Prognosen eine entscheidende Rolle. Hierfür können als einfaches

Beispiel AR-Modelle mit weiteren exogenen Variablen geschätzt und deren Prognosen verglichen und kombiniert werden.

Einstiegsliteratur: Ghysels und Marcellino (2018), Diebold und Mariano (1995) und Timmermann (2006)

- **Iterative vs. direkte Prognosen**

Liegt der Prognosehorizont mehr als eine Periode in der Zukunft, kann die Prognose auf zwei verschiedene Arten erstellt werden. Beim iterativen Verfahren wird ein Modell geschätzt und das Ergebnis aus der Ein-Schrittprognose in das Modell eingesetzt und somit für die Zwei-Schrittprognose weiterverwendet. Hingegen wird bei der direkten Prognose für jeden Prognosehorizont das Modell erneut geschätzt, so dass sich die geschätzten Parameter für die verschiedenen Prognosehorizonte unterscheiden. Im Rahmen der Arbeit soll die Inflationsrate oder das Wirtschaftswachstum sowohl mit dem iterativen als auch mit dem direkten Verfahren prognostiziert und mit dem Diebold-Mariano-Test überprüft werden, ob ein Verfahren signifikant bessere Prognosen liefert.

Einstiegsliteratur: Ghysels und Marcellino (2018) und Diebold und Mariano (1995), Marcellino et al. (2006)

- **Modellbasierte Prognosen vs. solcher von Analysten**

Eine interessante Fragestellung ist, ob Analysten über einen Informationsvorteil verfügen und bessere Prognosen liefern als selbst erstellte Prognosen. Um diese Frage zu beantworten, soll bei diesem Thema die Prognosegüte aus einfachen autoregressiven Modellen, evtl. mit einzelnen exogenen Variablen, mit der des Survey of Professional Forecasters mit Hilfe des Diebold-Mariano-Tests verglichen werden. Da viele Daten nur mit großer Verzögerung veröffentlicht und zudem revidiert werden, sollten Sie auf Echtzeitdaten zurückgreifen um einen fairen Vergleich der beiden Kontrahenten zu ermöglichen (Stark, 2010).

Einstiegsliteratur: Diebold und Mariano (1995), Stark (2010), Ghysels und Marcellino (2018) und Croushore und Stark (2019)

- **Faktormodelle für das Wirtschaftswachstum oder die Inflation**

Um mit großen Datensätzen, insbesondere mit einer großen Anzahl potentieller Erklärungsvariablen bei begrenzter Anzahl an Beobachtungen, umgehen und darauf aufbauend Analysen durchführen zu können, kann die Hauptkomponentenanalyse verwendet werden. Diese reduziert die Anzahl der erklärenden Faktoren, indem Kombinationen aus diesen gebildet werden, sog. Eigenfaktoren. Zunächst soll das Konzept der Hauptkomponentenanalyse erläutert und anschließend die extrahierten Hauptkomponenten zu autoregres-

siven Modellen hinzugefügt werden, um das Wirtschaftswachstum oder die Inflationsrate zu prognostizieren.

Einstiegsliteratur: James et al. (2021), Bai und Ng (2008), Stock und Watson (2002), McCracken und Ng (2016) und McCracken und Ng (2021)

- **Shrinkage Methoden in der makroökonomischen Prognose**

Eines der praktischen Probleme bei der Prognose besteht darin, die richtigen Regressoren für die zu prognostizierende Variable auszuwählen. Einerseits können wichtige Variablen fehlen, die unsere Prognose verbessern würden. Andererseits führt die Aufnahme irrelevanter Regressoren zu einer erhöhten Schätz- und damit verbundenen Prognoseunsicherheit. Eine Möglichkeit diesen Zielkonflikt zu lösen, ist die Einführung eines Strafterms bei der Schätzung der Parameter und der Auswahl der N Regressoren auf Basis des folgenden Minimierungsproblems:

$$\min_{\beta} \Phi(RSS) + \lambda\Psi(\beta_1, \dots, \beta_j, \dots, \beta_N)$$

Während eine Kleinste-Quadrate-Schätzung die Parameter β durch eine Minimierung der Residuenquadratsumme RSS schätzt, wird hier zusätzlich der Strafterm bzw. Shrinkage Parameter λ eingeführt. Φ und Ψ sind Funktionen der RSS und der zu den N Regressoren gehörenden Parametern β . Dieser Ansatz berücksichtigt explizit die Kreuzkorrelation zwischen den Regressoren bei der Minimierung der Verlustfunktion und verringert dadurch die Schätzunsicherheit. Ghysels und Marcellino (2018, Kapitel 1) bietet eine gute Übersicht über verschiedene Shrinkage Ansätze. Zunächst sollen ein bis zwei Shrinkage Ansätze vorgestellt werden und anschließend für die Prognose des Wirtschaftswachstums oder der Inflationsrate angewendet werden.

Einstiegsliteratur: Ghysels und Marcellino (2018), James et al. (2021), Sala-I-Martin (1997) und Medeiros et al. (2021)

- **Nahzeitprognose mit Modellen für gemischte Frequenzen**

Um bestimmte Variablen bereits im respektiven Quartal zu prognostizieren, werden oft Variablen als Prädiktor verwendet, die eine höhere Frequenz als die zu prognostizierende Variable aufweisen. Soll so z.B. das BIP prognostiziert werden, welches eine vierteljährliche Frequenz aufweist, so kann als Regressor die monatliche Variable der Industrieproduktion herangezogen werden. Da eine einfache Aggregation der Variablen mit einer höheren Frequenz zu einem Informationsverlust führen kann, wird an dieser Stelle die MIDAS Regression verwendet. Ein Vorteil dieser Methode ist insbesondere die sparsame Parametrisierung. Alternativ kann auch ein unrestringiertes MIDAS Modell verwendet werden um das BIP zu prognostizieren.

Einstiegsliteratur: Ghysels et al. (2004), Foroni und Marcellino (2014) und Ghysels und Marcellino (2018)

- **GARCH-Modelle zur Inflationsprognose und Growth-at-Risk**

Generalized Auto-Regressive Conditional Heteroscedasticity oder auch kurz GARCH Modelle dienen dazu Daten bei vorliegender Heteroskedastie zu modellieren. Meist in der Finanzwirtschaft verwendet, könne GARCH Modelle hier aber auch auf Inflationsdaten angewandt werden, da diese ebenfalls das Merkmal des Volatilitätsclustering aufweisen. Für das Wirtschaftswachstum kann mit Hilfe eines GARCH Modells der sogenannte Growth at Risk bestimmt werden, welcher Auskunft über die mögliche negative Wachstumsrate, gegeben der derzeitigen Situation gibt. Das Grundprinzip ist hierbei: Größere derzeitige Volatilität \Rightarrow größere Wahrscheinlichkeit für negatives Wachstum.

Einstiegsliteratur: Ghysels und Marcellino (2018), Engle (2001), Engle und Patton (2001), Bollerslev (1986) und Brownlees und Souza (2021)

- **Nichtlineare Modelle in der Makroökonomie**

In den anderen Themen haben wir die Annahme getroffen, dass die Modelle linear in den Parametern sind und diese über den gesamten Stichprobenzeitraum konstant sind. Es gibt jedoch Situationen, in denen solche Annahmen unplausibel sind. Übersteigt die Inflation bspw. ein bestimmtes Niveau kann es zu einer Hyperinflation kommen, in der sich die Dynamik der Inflation verändert. Gleichzeitig kann man sich vorstellen, dass die Staatsausgaben in Zeiten hoher öffentlicher Verschuldung weniger stark wachsen. Solche Nichtlinearitäten können vergleichsweise einfach mit TAR/STAR Modellen abgebildet werden. Im TAR-Modell ändern sich die Parameter im Laufe der Zeit abrupt, wenn eine Schwellenvariable einen Schwellenwert erreicht, während in STAR-Modellen der Übergang von dem alten zu den neuen Parameterwerten geglättet wird. Stellen Sie zunächst das TAR/STAR vor und erklären Sie die Vorgehensweise bei der Schätzung des Modells. Spannende Prognosevariablen sind das Wachstum der Industrieproduktion oder der Staatsausgaben sowie die Inflationsrate. Überprüfen Sie zudem, ob die nichtlinearen Modelle besser als lineare Varianten sind.

Einstiegsliteratur: Ghysels und Marcellino (2018), Ferrara et al. (2015) und Diebold und Mariano (1995)

Literaturverzeichnis

- Andersen, T. G., Bollerslev, T., Diebold, F. X. und Ebens, H. (2001). “The distribution of realized stock return volatility”. In: *Journal of Financial Economics* 61.1, Seiten 43–76.
- Andersen, T. G., Bollerslev, T., Diebold, F. X. und Labys, P. (2003). “Modeling and forecasting realized volatility”. In: *Econometrica* 71.2, Seiten 579–625.
- Bai, J. und Ng, S. (2008). “Large dimensional factor analysis”. In: *Foundations and Trends® in Econometrics* 3.2, Seiten 89–163.
- Bollerslev, T. (1986). “Generalized autoregressive conditional heteroskedasticity”. In: *Journal of Econometrics* 31.3, Seiten 307–327.
- Brownlees, C. und Souza, A. B. M. (2021). “Backtesting global growth-at-risk”. In: *Journal of Monetary Economics* 118, Seiten 312–330. ISSN: 0304-3932.
- Campbell, J. Y. und Shiller, R. J. (1987). “Cointegration and tests of present value models”. In: *Journal of Political Economy* 95.5, Seiten 1062–1088.
- Campbell, J. Y. und Shiller, R. J. (1988). “Interpreting cointegrated models”. In: *Journal of Economic Dynamics and Control* 12.2-3, Seiten 505–522.
- Cerchi, M. und Havenner, A. (1988). “Cointegration and stock prices - the random walk on Wall Street revisited”. In: *Journal of Economic Dynamics and Control* 12.2-3, Seiten 333–346.
- Chan, K. S. und Tong, H. (1986). “On estimating thresholds in autoregressive models”. In: *Journal of Time Series Analysis* 7.3, Seiten 179–190.
- Christoffersen, P. (2012). *Elements of Financial Risk Management*. 2. Auflage. Academic Press.
- Christoffersen, P. und Jacobs, K. (2004). “Which GARCH model for option valuation?” In: *Management Science* 50.9, Seiten 1204–1221.
- Clements, A. und Preve, D. P. A. (2021). “A practical guide to harnessing the HAR volatility model”. In: *Journal of Banking & Finance* 133.106285.
- Corsi, F. (2009). “A simple approximate long-memory model of realized volatility”. In: *Journal of Financial Econometrics* 7.2, Seiten 174–196.
- Croushore, D. und Stark, T. (2019). “Fifty years of the Survey of Professional Forecasters”. In: *Economic Insights* 4.4, Seiten 1–11.
- Diebold, F. X. und Mariano, R. S. (1995). “Comparing predictive accuracy”. In: *Journal of Business & Economic Statistics* 20.1, Seiten 134–144.
- Dijk, D. van, Teräsvirta, T. und Franses, P. H. (2002). “Smooth transition autoregressive models - A survey of recent developments”. In: *Econometric Reviews* 21.1, Seiten 1–47.
- Elliott, G., Granger, C. W. J. und Timmermann, A., Herausgeber (2006). *Handbook of Economic Forecasting*. Band 1. North-Holland.
- Engle, R. F. (2001). “GARCH 101: The use of ARCH/GARCH models in applied econometrics”. In: *Journal of Economic Perspectives* 15.4, Seiten 157–168.

- Engle, R. F. und Patton, A. J. (2001). “What good is a volatility model?” In: *Quantitative Finance* 1.2, Seiten 237–245.
- Ferrara, L., Marcellino, M. und Mogliani, M. (2015). “Macroeconomic forecasting during the Great Recession: The return of non-linearity?” In: *International Journal of Forecasting* 31.3, Seiten 664–679.
- Foroni, C. und Marcellino, M. (2014). “A comparison of mixed frequency approaches for nowcasting Euro area macroeconomic aggregates”. In: *International Journal of Forecasting* 30.3, Seiten 554–568. ISSN: 0169-2070.
- Ghysels, E. und Marcellino, M. (2018). *Applied economic forecasting using time series methods*. Oxford University Press.
- Ghysels, E., Santa-Clara, P. und Valkanov, R. (2004). “The MIDAS touch: Mixed data sampling regression models”. In: *UCLA Working Paper*.
- Ghysels, E., Sinko, A. und Valkanov, R. (2007). “MIDAS regressions: Further results and new directions”. In: *Econometric Reviews* 26.1, Seiten 53–90.
- Giglio, S. und Xiu, D. (2021). “Asset pricing with omitted factors”. In: *Journal of Political Economy* 129.7, Seiten 1947–1990.
- Gu, S., Kelly, B. und Xiu, D. (2020). “Empirical asset pricing via machine learning”. In: *The Review of Financial Studies* 33.5, Seiten 2223–2273.
- Hastie, T., Tibshirani, R. und Friedman, J. (2008). *The elements of statistical learning - data mining, inference, and prediction*. 2. Auflage. Springer Series in Statistics. Springer.
- J.P.Morgan und Reuters (1996). *Risk metrics - technical document*. Technischer Bericht.
- James, G., Witten, D., Hastie, T. und Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R*. eng. 2. Auflage. Springer Texts in Statistics. New York, NY: Springer. ISBN: 9781071614181.
- Koop, G. (1991). “Cointegration tests in present value relationships: A Bayesian look at the bivariate properties of stock prices and dividends”. In: *Journal of Econometrics* 49.1-2, Seiten 105–139.
- Kozak, S., Nagel, S. und Santosh, S. (2018). “Interpreting factor models”. In: *The Journal of Finance* 73.3, Seiten 1183–1223.
- Kuester, K., Mittnik, S. und Paolella, M. S. (2006). “Value-at-risk prediction: A comparison of alternative strategies”. In: *Journal of Financial Econometrics* 4.1, Seiten 53–89.
- Lundbergh, S. und Teräsvirta, T. (2002). “Evaluating GARCH models”. In: *Journal of Econometrics* 110.2, Seiten 417–435.
- Marcellino, M. und Schumacher, C. (2010). “Factor MIDAS for nowcasting and forecasting with ragged-edge data: A model comparison for German GDP”. In: *Oxford Bulletin of Economics and Statistics* 72.4, Seiten 518–550.

- Marcellino, M., Stock, J. H. und Watson, M. W. (2006). “A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series”. In: *Journal of Econometrics* 135.1, Seiten 499–526.
- McAleer, M. und Medeiros, M. C. (2008). “Realized volatility: A review”. In: *Econometric Reviews* 27.1-3, Seiten 10–45.
- McCracken, M. W. und Ng, S. (2016). “FRED-MD: A monthly database for macroeconomic research”. In: *Journal of Business & Economic Statistics* 34.4, Seiten 574–589.
- McCracken, M. W. und Ng, S. (2021). “FRED-QD: A quarterly database for macroeconomic research”. In: *Federal Reserve Bank of St. Louis Review* 103.1, Seiten 1–44.
- McNeil, A. J., Frey, R. und Embrechts, P. (2015). *Quantitative risk management - concepts, techniques and tools*. Revised Edition. Princeton Series in Finance. Princeton University Press.
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, A. und Zilberman, E. (2021). “Forecasting inflation in a data-rich environment: The benefits of machine learning methods”. In: *Journal of Business & Economic Statistics* 39.1, Seiten 98–119.
- Rapach, D. E. und Wohar, M. E. (2006). “The out-of-sample forecasting performance of nonlinear models of real exchange rate behavior”. In: *International Journal of Forecasting* 22.2, Seiten 341–361.
- Sala-I-Martin, X. X. (1997). “I just ran two million regressions”. In: *American Economic Review* 87.2, Seiten 178–183. ISSN: 00028282.
- Stark, T. (2010). “Realistic evaluation of real-time forecasts in the Survey of Professional Forecasters”. In: *Research Rap Special Report*.
- Stock, J. H. und Watson, M. W. (2002). “Macroeconomic forecasting using diffusion indexes”. In: *Journal of Business & Economic Statistics* 20.2, Seiten 147–162.
- Tibshirani, R. (1996). “Regression shrinkage and selection via the LASSO”. In: *Journal of the Royal Statistical Society - Series B (Methodology)* 58.1, Seiten 267–288.
- Timmermann, A. (2006). “Chapter 4 Forecast combinations”. In: Herausgegeben von Elliott, G., Granger, C. W. J. und Timmermann, A. Band 1. *Handbook of Economic Forecasting*. Elsevier, Seiten 135–196.
- Tsay, R. S. (2010). *Analysis of financial time series*. 3. Auflage. Wiley Series in Probability and Statistics. Wiley.
- Wang, L., Ma, F., Liu, J. und Yang, L. (2020). “Forecasting stock price volatility: New evidence from the GARCH-MIDAS model”. In: *International Journal of Forecasting* 36.2, Seiten 684–694.

Zhang, Y., Ma, F. und Wang, Y. (2019). “Forecasting crude oil prices with a large set of predictors: Can LASSO select powerful predictors?” In: *Journal of Empirical Finance* 54, Seiten 97–117.