

Master-Veranstaltungen der Lehrstühle Okhrin & Krapp

- Projekt: Data Science (WIW-5259)
- Projekt: Decision Science und Artificial Intelligence (WIW-5256)
- Selected Topics in Quantitative Methods (Masterseminar) (WIW-5175)

Einbringbar im Sommersemester 2023

Bearbeitbar schon ab Anfang März 2023

Bewerbungsphase von **20.01.2023** bis
28.02.2023



Themenübersicht

Titel	Für Bachelor oder Master (oder beide) ausgestaltbar		Bearbeitbar in		mit BMW
	Bachelor	Master	Augsburg	Teisendorf	
1. Fairness (Diskriminierung) in Machine Learning und Data Science	x	x	x	x	
2. LEN-Modelle	x	x	x	x	
3. Spektrale Risikomaße: Konzeption und betriebswirtschaftliche Anwendungen	x	x		x	
4. It's All About That Bayes!	x	x	x	x	
5. Entscheidungsregeln bei der Kreditvergabe bei BMW	X (höheres Semester)	x	x	x	x
6. Schätzung von Wahrscheinlichkeitsdichten	x	x	x	x	
7. Das Risiko-Orakel	x	x	x	x	
8. Vorhersage der Fahrzeugrückgabequote bei BMW	X (höheres Semester)	x	x	x	x
9. Does Money buy Happiness?	x		x	x	
10. Restwertvorhersage bei BMW	X (höheres Semester)	x	x	x	x
11. Algorithmic Trading mit Machine Learning Verfahren	X (höheres Semester)	x	x	x	
12. Erstellung von Scorecards im Risikomanagement mit Machine Learning Modellen	X (höheres Semester)	x	x	x	x
13. Schwarmintelligenz-Verfahren zur Lösung ökonomischer Problemstellungen	x	x		x	
14. Varianzreduktionsmethoden in der Simulation	X (höheres Semester)	x		x	



- Hochaktuelle Fragestellungen aus dem Bereich Data Science, Decision Science und Artificial Intelligence
- Einige **Themen in Kooperation mit BMW Financial Services**
- Neben der Bearbeitung fachlicher Inhalte steht auch die freie Rede und Präsentation eines Themas sowie der fachliche und persönliche Austausch mit Studierenden ähnlicher Interessen im Fokus
- **Leistung kann im Wesentlichen auch bereits in der vorlesungsfreien Zeit vorbereitet werden**
- Vorträge im Zweierteam
- Alternativ in Augsburg **oder** in Teisendorf
- Vorträge im Zweierteam
- Möglichkeit 1: 17.05.2023-21.05.2023.
 - Ederhof im oberbayerischen **Teisendorf**
 - Unterbringung in Ferienwohnungen auf dem Ederhof
 - Kosten für Unterbringung mit Frühstück: 140 Euro pro Person
- Möglichkeit 2 (**In Augsburg**, voraussichtlich in zeitlich unmittelbarer Nähe zur Veranstaltung in Teisendorf (Woche davor/Woche danach))



- BWL und EPP (PO 2017): Major/Minor Finance & Information, Major/Minor Operations & Information Management sowie General Management & Economics
- BWL und EPP (PO 2021): Major/Minor FACT, Major/Minor BAO
- GBM (PO 2011): Methoden
- DFM (PO 2011): Cluster Finance & Information Management und Cluster Operations & Information Management
- ReWi: SP: Bank, Kapitalmarkt und Finanzmanagement
- Informatik & Informationswirtschaft: Finance & Information
- WIN (PO 2017): Major/Minor: Operations, Finanz- und Informationsmanagement
- WING (PO 2014): Modulgruppe B: Major Management and Sustainability
- WIMA (PO 2013): Modulgruppe C1 (Finance & Information Management bzw. Modulgruppe C3 (Operations & Information Management)
- Master Mathe, Gruppe E-W: Nebenfach WiWi

[Siehe Modulhandbücher des Sommersemesters 2022](#) (Modulhandbuch des SoSe2023 wird identische Einbringbarkeiten für die Veranstaltung/en besitzen)



Die Prüfungsleistung besteht ausschließlich aus einem Vortrag im Zweier-Team, gestützt auf eine Präsentation.

Zu den Vorträgen:

- Vorträge im Zweierteam, frei gehalten
- Zieldauer 60 Minuten (gleichmäßig auf beide Vortragende aufgeteilt), anschließend Diskussion
- Beamer und 2 Notebooks vorhanden: eigene Notebooks mitbringen ist nicht notwendig.
- Kein Overheadprojektor, Flipchart o. Ä.
- Für das gesamte Publikum, nicht nur die Dozenten
- Handouts nicht erforderlich
- Die Präsentation ist als **wissenschaftliche Leistung in Präsentationsform** zu betrachten!
- Teilnahme an der Diskussion;
- Abgabe der Präsentation ausschließlich **in digitaler Form** bis Montag, 08.05.2023, 12:00 Uhr
- Gehalten werden die Vorträge **mit den am 08.05.2023 abgegebenen Präsentationen.**



- Bewerbung ab **20.01.2023** bis spätestens **28.02.2023 möglich**
- Die Auswahl und Themenvergabe erfolgt nach Leistungskriterien: Jede Bewerberin/Jeder Bewerber **muss daher neben seiner Online-Bewerbung während der Bewerbungsfrist einen aktuellen, vollständigen Studis-Auszug** per Mail an sebastian.heiden@wiwi.uni-augsburg.de schicken.
- Bewerbungsformular auf der Website des LS Okhrin (diese wird ab **20.01.2023** verfügbar sein)
 - Hierbei muss jedes Team eine Präferenzordnung von 5 Themen angeben
 - Somit werden wir versuchen, den Nutzen zu maximieren: Teams, welche ausgewählt wurden und nicht ihre Erstpräferenz bekommen, werden möglichst ihre nächste Präferenz(en) angeboten bekommen, falls sie ausgewählt wurden.
- Bewerbungen **als Zweierteam werden präferiert behandelt**: Hierbei sind als Team nur Gruppenzusammensetzungen Bachelor+Bachelor bzw. Master + Master möglich
- Jedes Thema wird **höchstens einmal vergeben**
- Themen- und Ortzusage **bereits Ende Februar 2023**
- **Nach der Themenvergabe Ende Februar 2023 kann (aber muß nicht!) bereits mit der Themenbearbeitung begonnen werden und ein Großteil des Arbeitsaufwandes kann somit bereits in der Vorlesungsfreien Zeit erbracht werden und entlastet das Semester**



Impressionen





Impressionen





Impressionen





Impressionen





Impressionen





Impressionen





Impressionen





Impressionen





Impressionen





1. Fairness (Diskriminierung) in Machine Learning und Data Science

Auch wenn Diskriminierung primär für menschliche Entscheidungen typisch ist, liefern Methoden und Verfahren des maschinellen Lernens Entscheidungen, die mit Diskriminierung vergleichbar sind, d.h. algorithmische Diskriminierung. Z.B. bei einer automatisierten Vorauswahl von Bewerbern auf eine Stelle oder bei Kreditwürdigkeitsprüfung können bestimmte Gruppen benachteiligt werden. Dies hat zur Folge, dass die aktuelle Forschung viel Wert auf „ethische“ KI-Systeme legt.

Aufgabenstellung

- Die Arbeit soll das Problem und die Gründe der Diskriminierung in KI/ML darstellen und auch Lösungsmöglichkeiten zur Quantifizierung und Behebung der Diskriminierung darstellen. .

Ausgangsliteratur

- Mehrabi, Ninareh, Morstatter, Fred, Saxena, Nripsuta, Lerman, Kristina und Galstyan, Aram: A Survey on Bias and Fairness in Machine Learning. URL <http://arxiv.org/pdf/1908.09635v2>
- Gajane, Pratik und Pechenizkiy Mykola: On Formalizing Fairness in Prediction with Machine Learning. In: , 2018. URL <https://arxiv.org/pdf/1710.03184.pdf>
- Verma, Sahil, Ernst, Michael und Just, Rene: Removing biased data to improve fairness and accuracy. 2021. <https://arxiv.org/pdf/2102.03054>
- Eigene Recherche

Betreuer: Yarema Okhrin

LEN-Modelle zeichnen sich durch die Kombination der Annahmen linearer Zusammenhänge (L), exponentieller Risikonutzenfunktionen (E) und normalverteilter Risiken (N) aus. Dieses spezifische Gerüst ermöglicht Lösungen auf Basis leicht interpretierbarer und analytisch gut handhabbarer (μ, σ) -Regeln. Dementsprechend werden LEN-Modelle häufig für die Formulierung ökonomischer Entscheidungsmodelle eingesetzt. Speziell im Kontext der Prinzipal-Agent-Theorie, welche Vertragsbeziehungen zwischen mindestens zwei Parteien bei Unsicherheit, Informationsasymmetrie und Zieldivergenz untersucht, sind LEN-Modelle sehr populär.

Aufgabenstellung

- Erläuterung der grundsätzlichen Funktionsweise von LEN-Modellen.
- Formulierung und explizite Lösung eines LEN-basierten Prinzipal-Agent-Modells.
- Veranschaulichung anhand selbst erstellter numerischer Beispiele.
- Ggf. Überblick über weitere Einsatzmöglichkeiten von LEN-Modellen.

Ausgangsliteratur

- Holmstrom B, Milgrom P (1987): Aggregation and linearity in the provision of intertemporal incentives. *Econometrica* 55: 303-328
- Spremann K (1987): Agent and Principal, in: Bamberg G, Spremann K (Eds.), *Agency theory, information, and incentives*, Springer, Berlin et al.: 3-37
- Eigene Recherche

Betreuer: Michael Krapp

Hinweis: Der Grad des mathematischen Anspruches hängt davon ab, ob das Thema von Bachelor- oder von Masterstudierenden bearbeitet wird.



3. Spektrale Risikomaße: Konzeption und betriebswirtschaftliche Anwendungen

Zur Regulierung des Bankensektors sind Maßzahlen erforderlich, die eine risikoadjustierte Quantifizierung der vorzuhaltenden Eigenmittel ermöglichen. Durch sinnvolle Forderungen (Axiome) wurden „kohärente“ Risikomaße definiert. Der bekannte Conditional Value-at-Risk gehört zu dieser Klasse von Risikomaßen. Er wird von wissenschaftlicher Seite dem in der Praxis benutztem (nichtkohärenten) Value-at-Risk vorgezogen. Eine wichtige Subklasse der kohärenten Risikomaße bilden die spektralen Risikomaße.

Aufgabenstellung

- Darstellung und ausführliche Begründung der operationellen Vorteile der spektralen Risikomaße
- Betrachtung und Darstellung der Vor- und Nachteile der spektralen Risikomaße in Standard-Problemstellungen
- Diskussion der Eignung der Risikomaße in den Bereichen wie Portfoliobildung und Rückversicherung
- Darstellung und Vergleich der verschiedenen Risikomaße durch selbst gewählte Zahlenbeispiele und durch selbst gewählte Daten (mit Excel oder R möglich).

Ausgangsliteratur

- Brandtner, M. (2016), Spektrale Risikomaße: Konzeption, betriebswirtschaftliche Anwendungen und Fallstricke, Management Review Quarterly 66, S. 75-115.
- Eigene Recherche

Betreuer: Günter Bamberg (Autor des Statistik-Buches Bamberg/Baur/Krapp der Statistik-Vorlesungen)

Hinweis: Dieses Thema wird nur für den Vortragsort Teisendorf angeboten



4. It's All About That Bayes!

Die Bayes-Statistik gewann in den letzten Jahrzehnten zunehmend an Bedeutung – fristet jedoch in den Wirtschaftswissenschaften nach wie vor ein Schattendasein. Zu stark ist das Feld durch die klassische, frequentistische Statistik geprägt.

Dieses Fokussieren auf den klassischen Wahrscheinlichkeitsbegriff birgt zwei Gefahren: Zum einen verfestigt es die Vorstellung von der klassischen Statistik als „wahre“ Statistik. Das ist problematisch, da die frequentistische Statistik keinesfalls ahistorisch ist und auf zahlreichen grundsätzlichen Annahmen fußt. Zum anderen bleibt durch das Nicht-Nutzen der bayesianischen Vorgehensweise analytisches Potential in den Wirtschaftswissenschaften ungenutzt.

Aufgabenstellung

- Aufzeigen der Historizität der Statistik und Gegenüberstellung des *objektiven* und des *subjektiven* Wahrscheinlichkeitsbegriffs
- Einführung in die Bayes-Statistik durch das Vorstellen der (Conjugate-)Priori-, der Likelihood- und der Posteriori-Verteilung
- Bayesianische Inferenz: Posterior-Mean, Posterior-Intervals, Hypothesentests, Posterior Predictive Distribution
- Empirische Untersuchung anhand des *Student Dataset*

Ausgangsliteratur

- Jim Albert (2009). Bayesian Computation with R: [978-0-387-92298-0.pdf \(springer.com\)](https://www.springer.com/9780387922980)
- Mary Kathryn Cowles (2013). Applied Bayesian Statistics: [978-1-4614-5696-4.pdf \(springer.com\)](https://www.springer.com/9781461456964)
- Jean-Michel Marin & Christian Robert (2014). Bayesian Essentials with R: [978-1-4614-8687-9.pdf \(springer.com\)](https://www.springer.com/9781461486879)

Betreuerin: Christine Distler



5. Entscheidungsregeln bei der Kreditvergabe bei BMW

Heutzutage sind automatisierte Entscheidungsregeln ein wichtiger Bestandteil des Kreditvergabeprozesses. Ein geeigneter Satz von Regeln und Schwellenwerten kann das Kreditrisiko minimieren und den manuellen Aufwand erheblich reduzieren. Der Optimierungsprozess von solchen Entscheidungsregeln ist jedoch komplex. Ziel dieser Seminararbeit ist eine Methodik zur Optimierung der Entscheidungsregeln zu erarbeiten, basierend auf einem geeigneten Beispiel. Dabei sollen zwei oder mehrere Klassifizierungsalgorithmen (wie z.B. Entscheidungsbäume) verwendet werden.

Aufgabenstellung

- Mehrere Klassifikationsverfahren (Entscheidungsbäume etc) sollen erläutert und mit Realdaten eingesetzt werden
- Die Klassifikationsverfahren sollen bezüglich ihrer Güte verglichen werden
- Der Datensatz für diese Forschung wird anonymisierte reale Daten für einen der globalen Märkte von BMW Financial Services enthalten.

Ausgangsliteratur

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning.
- Hyndman, R.J., & Athanasopoulos, G. (2021) Forecasting: principles and practice, 3rd edition, OTexts: Melbourne, Australia. [OTexts.com/fpp3](https://otexts.com/fpp3)
- Eigene Recherche (Nach Absprache mit der Betreuerin)
- Datensatz von BMW Financial Services

Betreuerin: Christine Distler & Betreuer/In von BMW Financial Services



6. Schätzung von Wahrscheinlichkeitsdichten

Oftmals werden in der Statistik und im Machine Learning nur einzelne Kennzahlen von Zufallsvariablen modellieren, wie z.B. der Erwartungswert oder der Median. Durch den Fokus auf einzelne Kennzahlen geht oftmals Information über die betrachtete Zufallsvariable verloren. Dies kann verhindert werden indem die gesamte Wahrscheinlichkeitsdichte modelliert wird. Zusätzlich werden geschätzte Wahrscheinlichkeitsdichten häufig verwendet um Annahmen bestimmter Modelle wie der linearen Regression zu testen.

Aufgabenstellung

- Darstellung der theoretischen Grundlagen (Zufallsvariable, Verteilung, Dichte)
- Vorstellung verschiedener Ansätze zur Schätzung von Wahrscheinlichkeitsdichten (Histogramm, Kerndichteschätzer, Histogramm Smoothing)
- Implementierung der Ansätze an einem Datensatz in *R* oder Python.
- Interpretation und Vergleich der Ergebnisse

Ausgangsliteratur

- Fahrmeir, L.; Pigeot, I. & Tutz, G. (2003), Statistik. Der Weg zur Datenanalyse , Springer Verlag , München.
- Silverman, B.W. (1998). Density Estimation for Statistics and Data Analysis (1st ed.). Routledge.
- Paul H. C. Eilers. Brian D. Marx. "Flexible smoothing with B-splines and penalties." Statist. Sci. 11 (2) 89 - 121, May 1996.

Betreuer: Alexander Fottner

Ein relevantes Thema für an Finanzmärkten handelnde Personen ist die Quantifizierung des Risikos, welches einer Aktie innewohnt. Man möchte abschätzen können, wie schlimm etwaige Verluste durch Kurseinbrüche ausfallen können. Ein populäres Risikomaß in diesem Zusammenhang ist der sogenannte Value at Risk (VaR). Es gibt mehrere Methoden den VaR für eine Aktie vorherzusagen. Nach einem gewissen Zeitraum können die Methoden anhand verschiedener Tests evaluiert und miteinander verglichen werden.

Aufgabenstellung

- Darstellung des VaR für eine einzelne Aktie.
- Darstellung von VaR-Vorhersage-Methoden basierend auf GARCH und EWMA.
- Erstellung numerisches Beispiel: die zwei Methoden angewandt auf eine Aktie (freie Wahl).
- Darstellung des Kupiec POF Test für den VaR und Anwendung auf das num. Beispiel.
- Darstellung des Christoffersen (1998)-Test für den VaR und Anwendung auf das num. Beispiel.

Ausgangsliteratur

- Ruppert D. (2004): Statistics and Finance, Springer New York.
- McNeil A. J. et al. (2015): Quantitative Risk Management, Princeton Series in Finance.
- Campbell S. D. (2005): A Review of Backtesting and Backtesting Procedures.
- Christoffersen P., "Evaluating Interval Forecasts," International Economic Review, 39, 1998, 841-862.
- Skript Risikomanagement.

Betreuer: Philipp Haid

Hinweis: Dieses Thema richtet sich primär an Bachelor-Studierende.



8. Vorhersage der Fahrzeugrückgabequote bei BMW

BMW Financial Services bietet wir Fahrzeugfinanzierungen an, bei denen die Kunden am Ende der Vertragslaufzeit wählen können, ob sie das Fahrzeug behalten oder ohne zusätzliche Kosten zurückgeben möchten. Eine Einschätzung von Anzahl der Fahrzeuge, die zurückkommen, ist daher von entscheidender Bedeutung. Da die Elektromobilität immer mehr an Bedeutung gewinnt, wird die Einschätzung des Kundenverhalten in diesem Zusammenhang noch schwieriger. Eine Möglichkeit, dies zu modellieren, besteht darin, ein logistisches Regressionsmodell zu erstellen, das auf einem riesigen Pool von Vergangenheitsdaten basiert und eine Rückgabewahrscheinlichkeit für jedes einzelne Fahrzeug im Pool von BMW soll prognostiziert werden.

Aufgabenstellung

- Verschiedene maschinelle Lerntechniken sollen mit dem grundlegenden logistischen Regressionsmodell auf der Grundlage verschiedener Kriterien verglichen werden
- Die gewählten Modelle sollen transparent und nachvollziehbar erklärt werden
- Zielgröße soll die möglichst gute Vorhersage der Rückgabewahrscheinlichkeit eines Fahrzeugmodells sein

Ausgangsliteratur

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning.
- Hyndman, R.J., & Athanasopoulos, G. (2021) Forecasting: principles and practice, 3rd edition, OTexts: Melbourne, Australia. [OTexts.com/fpp3](https://otexts.com/fpp3)
- Eigene Recherche (Nach Absprache mit de Betreuer)
- Der Datensatz wird reale Daten für einen der globalen Märkte von BMW enthalten

Betreuer: Philipp Haid & Betreuer/In von BMW Financial Services

Sowohl Psychologen als auch Ökonomen waren sich lange Zeit darüber relativ einig, dass Geld zwar einen statistisch signifikanten Einfluss auf das wahrgenommene Glück von Individuen hat, dies aber nur bis zu einem bestimmten Punkt zutrifft: Jenseits dieses Einkommens führen weitere monetäre Zuflüsse aber nur zu unwesentlicher weiterer Zunahme des persönlichen Nutzens. Dies widerspricht der klassischen ökonomischen Denke, dass Geld Individuen Nutzen stiftet und der Lehrmeinung, dass der Nutzen von weiteren Geldeinheiten zunehmend sein muss, da diese neue Möglichkeiten eröffnet, welche „ärmeren“ Personen nicht zur Verfügung stehen. Für beide Denkschulen gibt es ökonomische Studien, welche dies anhand von Daten untersuchen und zu unterschiedlichen Schlussfolgerungen kommen.

Aufgabenstellung

- Ausgehend von mehreren Publikationen sollen die ursprünglichen Ergebnisse und heutige Erkenntnisse der Literatur zum Thema „Macht Geld glücklich?“ gegenübergestellt werden
- Thematisiert werden muss wie Zufriedenheit gemessen wird und welche Modelle eingesetzt werden, um zu den statistischen Schlussfolgerungen zu kommen
- Auch die jeweilig verwendete Datenbasis soll vorgestellt und diskutiert werden

Ausgangsliteratur

- Headey, Muffels, Wooden (2004); Money doesn't buy Happiness..Or Does It? A Reconsideration Based on the Combined Effects of Wealth, Income and Consumption"; Discussion Paper
- Gardner, Oswald (2001); "Does Money Buy Happiness? A Longitudinal Study Using Data on Windfalls", Discussion Paper.
- Bodkin (1959); Windfall Income and Consumption; American Economic Review.
- Eigene Recherche

Betreuer: Sebastian Heiden

Hinweis: Dieses Thema wird nur an Bachelor-Studierende vergeben.



10. Restwertvorhersage bei BMW

BMW Financial Services bietet Fahrzeugfinanzierungen an, bei der die Kunden am Ende der Vertragslaufzeit wählen können, ob sie das Fahrzeug behalten oder ohne zusätzliche Kosten zurückgeben möchten. Eine Einschätzung zu haben, welchen Wert dieses Fahrzeug zu einem zukünftigen Zeitpunkt im Vergleich zu seinem Neuwagenwert haben wird, ist für BMW entscheidend, da dies das Risiko darstellt. Mit der zunehmenden Bedeutung der Elektromobilität ist diese Vorhersage schwieriger geworden, da der Automarkt sich im strukturierten Wandel befindet. Eine Möglichkeit, dies zu modellieren, besteht darin, eine multivariate lineare Regression zu erstellen, die eine Vorhersage der zukünftigen Gebrauchtwagenwerte für die Fahrzeuge liefert, die BMW derzeit in jedem Markt verkauft.

Aufgabenstellung

- Verschiedene maschinelle Lerntechniken sollen mit dem grundlegenden multivariaten linearen Regressionsmodell auf der Grundlage verschiedener Kriterien verglichen werden
- Die gewählten Modelle sollen transparent und nachvollziehbar erklärt werden
- Zielgröße soll die möglichst gute Vorhersage des Restwertes eines Fahrzeugmodells sein

Ausgangsliteratur

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning.
- Hyndman, R.J., & Athanasopoulos, G. (2021) Forecasting: principles and practice, 3rd edition, OTexts: Melbourne, Australia. [OTexts.com/fpp3](https://otexts.com/fpp3)
- Eigene Recherche (Nach Absprache mit dem Betreuer)
- Der Datensatz wird reale Daten für einen der globalen Märkte von BMW enthalten

Betreuer: Sebastian Heiden & Betreuer/In von BMW Financial Services



11. Algorithmic Trading mit Machine Learning Verfahren

Algorithmic Trading bezeichnet ein Verfahren zur Ausführung von Aufträgen unter Verwendung automatisierter und vorprogrammierter Handelsanweisungen. In den 90er Jahren fand die quantitative Revolution an den Kapitalmärkten statt, als Computer leistungsfähig genug wurden, um mithilfe von vorprogrammierten Regeln Handel zu treiben. Mit den Fortschritten in Machine Learning und Big Data sehen viele Experten eine zweite quantitative Revolution bevorstehend.

Aufgabenstellung

- Darlegung des State-of-the-arts in Algorithmic Trading (mit ML Verfahren)
- Allgemeine Erklärung und Einführung in Algorithmic Trading mit ML Verfahren
- Erstellung eines Algorithmic Trading Modells mit angewandten ML Verfahren in Python

Ausgangsliteratur

- Stefan Jansen (2020), Machine Learning for Algorithmic Trading: Predictive models to extract signals from market and alternative data for systematic trading strategies with Python, Packt Verlag, ISBN: 1839217715.

Betreuer: Jonathan Pfahler



12. Erstellung von Scorecards im Risikomanagement mit Machine Learning Modellen

Die Entwicklung von Scorecards ist ein wichtiges Thema im Kreditrisikomanagement. Scorecards werden in Banken für Risikorückstellungen und Entscheidungsprozesse verwendet. Die logistische Regression ist aufgrund ihrer Transparenz ein gängiger statistischer Algorithmus für die Entwicklung von Scorecards. In dieser Untersuchung soll eine Scorecard auf der Grundlage eines alternativen Algorithmus zur Lösung des Klassifizierungsproblems entwickelt werden. Die Transparenz der Ergebnisse soll im Detail diskutiert werden. Der Datensatz für diese Untersuchung wird anonymisierte reale Daten für einen unserer globalen Märkte umfassen.

Aufgabenstellung

- Der Nutzen von Scorecards im Risikomanagement soll verstanden werden.
- Zwei Scorecards sollen erstellt werden basierend auf dem gegebenen Datensatz.
- Für die erste Scorecard soll die logistische Regression verwendet werden, um Elemente der Scorecard zu schätzen.
- Für die zweite Scorecard soll ein alternatives Modell aus dem Bereich Machine Learning verwendet werden, um Elemente der Scorecard zu schätzen.

Ausgangsliteratur

- *Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani. An Introduction to Statistical Learning : with Applications in R. New York :Springer, 2013.*
- *Literatur aus eignener Recherche*
- *Realdaten von BMW Financial Services*

Betreuer: Jonathan Pfahler & Betreuer/In von BMW Financial Services

Hinweis: Dieses Thema wird nur an Masterstudierende vergeben. Dieses Thema wird in Kooperation mit BMW Financial Services angeboten



13. Schwarmintelligenz-Verfahren zur Lösung ökonomischer Problemstellungen

In vielen Problemstellungen ist der Einsatz von exakten Verfahren, welche die Optimalität der gefundenen Lösung garantieren, keine adäquate Wahl. Dies ist vor allem auf die mit zunehmender Modellgröße steigende Rechenzeit zurückzuführen. Stattdessen werden oftmals Heuristiken angewendet, die zwar keine optimale Lösung garantieren, im Gegensatz dazu jedoch deutlich bessere Resultate hinsichtlich der benötigten Rechenzeit erzielen. Eine Vielzahl dieser Heuristiken basiert auf Konzepten der Schwarmintelligenz. Eines dieser Verfahren ist der sogenannte Particle Swarm Optimization (PSO) Algorithmus, welcher vom Bewegungsverhalten einzelner Individuen in Schwärmen in der Natur inspiriert ist.

Aufgabenstellung

- Einführung und Erläuterung von PSO
 - Überblick über weit verbreitete Varianten
 - Gegenüberstellung: deterministische vs. stochastische Ansätze
- Implementierung eines PSO Ansatzes und Anwendung auf ein ausgewähltes stochastisches Problem
- Vorstellung der empirischen Ergebnisse

Ausgangsliteratur

- Poli, Riccardo, James Kennedy, and Tim Blackwell. "Particle swarm optimization." *Swarm intelligence* 1.1 (2007): 33-57.
- Eigene Recherche (nach Absprache mit dem Betreuer)

Betreuer: Deniz Preil

Hinweis: Dieses Thema wird nur für den Vortragsort Teisendorf angeboten

In einer Vielzahl an Problemstellungen existiert aufgrund deren Komplexität, insbesondere durch den Einfluss von stochastischen Einflussfaktoren, kein (bekannter) algebraischer Ausdruck der Zielfunktion. In solchen Fällen wird meist auf Simulationsmodelle zurückgegriffen mit dem Ziel, das zugrundeliegende Problem heuristisch zu lösen, obgleich die Lösungsfindung auch in diesem Fall durch den Einfluss der stochastischen Einflussfaktoren erschwert wird. Um die volatile Lösungsgüte der Entscheidungsvariablen zu reduzieren, existieren unterschiedliche Varianzreduktionsverfahren wie z.B. das „Antithetic Sampling“ (AS). Ziel der Arbeit ist es, ausgewählte ökonomische Problemstellungen aus der Literatur im Rahmen von Simulationsmodellen in einer selbst gewählten Programmiersprache zu implementieren und den Einsatz unterschiedlicher Varianzreduktionsmethoden zu evaluieren.

Aufgabenstellung

- Einführung in den Themenkomplex „Simulationsierte Optimierung“
- Implementierung ausgewählter ökonomischer Problemstellungen im Rahmen von Simulationsmodellen (programmierlastig)
- Einführung und Erläuterung unterschiedlicher Varianzreduktionsmethoden (insbesondere AS)
- Evaluation der verwendeten Varianzreduktionsmethoden anhand der implementierten Simulationsmodelle

Ausgangsliteratur

- Eigene Recherche (nach Absprache mit dem Betreuer)

Betreuer: Deniz Preil

Das Betrugsrisiko ist ein Risikoart im Kreditvergabeprozess. Um dieses Risiko zu minimieren, ist es notwendig, gewisse Muster zu untersuchen, die eine hohe Betrugswahrscheinlichkeit vorhersagen. Eine Besonderheit bei Betrugserkennung ist eine geringe Anzahl von Beobachtungen, um diese Muster zu erkennen. Ziel dieser Arbeit ist es, mittels Methoden aus dem Bereich des „Machine Learning“ ein Instrument zur Betrugserkennung zu erarbeiten. Der Datensatz für diese Arbeit wird anonymisierte reale Daten für einen der globalen Märkte des Praxispartners enthalten.

Aufgabenstellung

- Einführung in die Problemstellung
- Vorstellung und Erläuterung adäquater Verfahren zur Betrugaufdeckung aus dem Bereich des „Machine Learning“
- Implementierung ausgewählter Verfahren in Bezug auf die Problemstellung des Praxispartners
- Evaluation der Ergebnisse

Ausgangsliteratur

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning.
- Eigene Recherche (nach Absprache mit dem Betreuer)
- ***Realdaten von BMW Financial Services***

Betreuer: Deniz Preil & Betreuer/In von BMW Financial Services

Hinweis: Das Thema wird in Kooperation mit BMW Financial Services angeboten