

*Band
18*

Bianca Krol (Hrsg.)

*Prognosemodelle für Länderrisiken:
Logit- und Deep Learning-Methoden
im Vergleich*

~
Daniel Hagemann, Frank Lehrbass

ifes Schriftenreihe

FOM
Hochschule

ifes

Institut für Empirie & Statistik
der FOM Hochschule
für Oekonomie & Management

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliographie; detaillierte bibliographische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

© 2018 by



**Akademie
Verlags- und Druck-
Gesellschaft mbH**

MA Akademie Verlags- und Druck-Gesellschaft mbH
Leimkugelstraße 6, 45141 Essen
info@mav-verlag.de

Das Werk einschließlich seiner Teile ist urheberrechtlich geschützt. Jede Verwertung außerhalb der engen Grenzen des Urhebergesetzes ist ohne Zustimmung der MA Akademie Verlags- und Druck-Gesellschaft mbH unzulässig und strafbar. Das gilt insbesondere für Vervielfältigungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen. Die Wiedergabe von Gebrauchsnamen, Handelsnamen, Warenbezeichnungen usw. in diesem Werk berechtigt auch ohne besondere Kennzeichnung nicht zu der Annahme, dass solche Namen im Sinne der Warenzeichen- und Markenschutz-Gesetzgebung als frei zu betrachten wären und daher von jedermann benutzt werden dürfen. Oft handelt es sich um gesetzlich geschützte eingetragene Warenzeichen, auch wenn sie nicht als solche gekennzeichnet sind.

Daniel Hagemann, Frank Lehrbass

**Prognosemodelle für Länderrisiken:
Logit- und Deep Learning-Methoden im Vergleich**

ifes Institut für Empirie & Statistik
der FOM Hochschule für Oekonomie & Management

ifes Schriftenreihe
Band 18, 2018

ISBN (Print) 978-3-89275-411-4 ISSN (Print) 2191-3366
ISBN (eBook) 978-3-89275-412-1 ISSN (eBook) 2569-5355

Essen

Inhaltsverzeichnis

Tabellenverzeichnis	IV
Formelverzeichnis.....	IV
1 Einleitung	5
2 Aktueller Forschungsstand und mögliche Determinanten.....	7
3 Empirische Auswertung	9
3.1 Ordered Logit-Modell.....	9
3.2 Datensatz und Datenaufbereitung	10
3.3 Ergebnisse.....	12
3.4 Prognosequalität des Modells.....	13
3.5 Logit-Modell	14
4 Prognosemodelle	17
4.1 Logit-Prognosemodell	17
4.2 Deep Learning-Prognosemodelle.....	18
4.3 Fallstudie Italien	21
5 Fazit und Ausblick.....	22
Literaturverzeichnis	23

Tabellenverzeichnis

Tab. 1: Aggregation der Ratingskala	9
Tab. 2: Ratingverteilung	10
Tab. 3: Operationalisierung der Determinanten.....	11
Tab. 4: Schätzergebnisse Ordered Logit-Modell	12
Tab. 5: Konfusionsmatrix Ordered Logit-Modell in-sample	13
Tab. 6: Konfusionsmatrix Ordered Logit-Modell out-of-sample	14
Tab. 7: Schätzergebnisse Logit-Modell	15
Tab. 8: Konfusionsmatrix Logit-Modell in-sample.....	16
Tab. 9: Schätzergebnisse Logit-Modell 2	17
Tab. 10: Konfusionsmatrix Logit-Modell 2 in-sample.....	18
Tab. 11: Konfusionsmatrix Logit-Modell 2 out-of-sample.....	18
Tab. 12: Lernergebnisse Input Schicht	19
Tab. 13: Lernergebnisse Hidden Schicht.....	20
Tab. 14: Konfusionsmatrix Deep Learning-Modell in-sample	20
Tab. 15: Konfusionsmatrix Deep Learning-Modell out-of-sample	20

Formelverzeichnis

Formel 1: Latentes Schätzmodell.....	9
Formel 2: Ordered Logit-Modell	10

1 Einleitung

Früher spielten Länderrisiken meist nur bei der Betrachtung von Entwicklungsländern eine Rolle. Doch hat die jüngere Vergangenheit gezeigt, dass dieses Thema auch für die entwickelten Staaten von Bedeutung ist. So stufte beispielsweise die Ratingagentur Moody's die Kreditwürdigkeit Griechenlands am 14. Juni 2010 um vier Notches von A3 auf Ba1 herab. Dieser Downgrade gilt als Katalysator der europäischen Staatsschuldenkrise. Moody's begründete das Multi-Notch-Downgrade insbesondere mit dem erhöhten Risiko, dass sich die Schuldentragfähigkeit Griechenlands trotz des vereinbarten milliarden schweren Hilfspakets durch die Eurozone und den Internationalen Währungsfonds mittelfristig als nicht mehr nachhaltig erweisen könnte. Als sich die Verschuldung Griechenlands in Relation zum Bruttoinlandsprodukt (BIP) nicht stabilisierte, folgten weitere Downgrades der Ratingagentur.

Die mehrfachen Ratingherabstufungen Griechenlands in den Jahren 2010 bis 2012 zeigen, dass das Rating von Staaten sehr sensitiv auf bestimmte Kennzahlen reagieren kann. Insbesondere die Überschreitung bestimmter Schwellenwerte kann sich schlagartig auf die Bonitätseinschätzung auswirken und zu einer entsprechenden Erhöhung der Länderrisikoprämien führen.

Dass in Europa immer noch Handlungsbedarf hinsichtlich des Länderrisikos besteht, belegt der Vorschlag zur Reform des Euroraums einer Gruppe prominenter deutscher und französischer Ökonominnen und Ökonomen.¹ Die Nachfrage nach Anleihen der bonitätsschwächeren Länder dürfte etwa durch die vorgeschlagenen Risikokonzentrationszuschläge ("sovereign concentration charges") reduziert werden. Ceteris paribus führt dies zu einem Anstieg der Länderrisikoprämien. In dieselbe Richtung zeigt die bankaufsichtliche Diskussion. Ein Wegfall der Privilegierung bei der (Null-) Risikogewichtung, die aktuell von allen in Basel involvierten Aufsehern praktiziert wird, liegt als Vorschlag auf dem Tisch.²

Hinzu kommt eine sich verstärkende Gefahrenlage durch sogenannte "nicht-kooperative Regierungen".³ Diese agieren bewusst gegen die Regelwerke ("Brüsseler Diktat") und damit länderrisikoerhöhend.

Deshalb ist es bedeutsam, die Entwicklung der Ratings von Staaten abschätzen zu können. Insbesondere interessiert dabei der Übergang zwischen Investmentgrade und Subinvestmentgrade.

In diesem Beitrag bestimmen wir die Determinanten der RatingEinstufung von Staaten empirisch. Es wird zuerst ein Ordered Logit-Modell vorgestellt, mit welchem sich das Rating prognostizieren lässt. Dabei wird auf die Ratings von

¹ Vgl. Bénassy-Quéré, A. et al., 2018, S. 1 ff.

² Vgl. Basel Committee on Banking Supervision, 2017, S. 1 ff.

³ Vgl. Heinemann, F., 2018, S. 2.

Moody's und die volkswirtschaftlichen Kennzahlen von Moody's und Fitch zurückgegriffen. Der Datensatz beinhaltet 124 von Moody's geratete Staaten. Danach wird der Fokus auf die Vorhersage eines (Sub-)Investmentgrade-Ratings gelegt, da dies eine zentrale Unterscheidung ist. Ein Logit-Modell tritt dabei gegen Deep Learning basierte Prognosemodelle an. Mit dem besten Modell⁴ wagen wir eine Vorausschau auf die zukünftige Bonität Italiens.

⁴ Die Modelle werden in-sample entwickelt und out-of-sample getestet. Die out-of-sample Trefferquote (Hit Rate) ist unser Gütekriterium.

2 Aktueller Forschungsstand und mögliche Determinanten

Das Ratingprocedere bei Staaten ist anders als bei Unternehmen. Aufgrund ihres Einblicks in die Unternehmen kann die Ratingagentur Insiderinformationen verarbeiten. Bei Staaten basieren die Ratings jedoch auf öffentlich zugänglichen Informationen. Insofern ist ein quantitativer Ansatz vielversprechend.

Wir verbinden den Literaturüberblick mit der Einführung möglicher Determinanten.⁵ Die maßgeblichen Bonitätsdeterminanten von Staaten sind makroökonomischer Natur und lassen sich in binnenwirtschaftliche Risikofaktoren, fiskalische Risikofaktoren und außenwirtschaftliche Risikofaktoren unterscheiden. Die wichtigsten Subfaktoren dieser drei Kategorien werden nachfolgend in eben dieser Reihenfolge vorgestellt:

BIP pro Kopf: Das BIP pro Kopf ist ein Indikator für die potenzielle Steuerbasis eines Staates. Darüber hinaus ist das BIP pro Kopf ein Proxy für den Entwicklungsstand einer Volkswirtschaft⁶ sowie für die politische und institutionelle Stabilität eines Staates.⁷

Reales BIP-Wachstum: Ein positives reales BIP-Wachstum sichert langfristig die Wirtschaftskraft und verbreitert die Steuerbasis einer Volkswirtschaft. Des Weiteren senkt ein positives BIP-Wachstum ceteris paribus die relative Verschuldung.

Arbeitslosenquote: Eine geringe Arbeitslosigkeit deutet auf eine gute konjunkturelle Situation einer Volkswirtschaft sowie auf einen flexiblen Arbeitsmarkt hin. Zudem sinken die Ausgaben für die Sozialsysteme, während gleichzeitig die Steuerbasis verbreitert wird.⁸

Inflationsrate: Der Einfluss der Inflationsrate auf die Kreditwürdigkeit eines Staates ist nicht eindeutig. Fiskalisch sinkt bei einer hohen Inflationsrate der reale Wert der in heimischer Währung denominierten Staatsverschuldung. Gleichzeitig dürften jedoch die nominalen Zinsen und damit die Zinslast des Staates steigen, was wiederum zu einer höheren Verschuldung führt.⁹ Eine niedrige Inflation ist ein Indiz für eine nachhaltige und unabhängige Geldpolitik sowie für institutionelle Stabilität.¹⁰ Stark inflationäre Entwicklungen wirken sich wiederum negativ auf das Wirtschaftswachstum aus und deuten auf strukturelle Probleme einer Volkswirtschaft hin.¹¹ Insgesamt wird daher ein negativer quadratischer Zusammenhang zwischen der Inflationsrate und der Bonität eines Staates angenommen.

⁵ Eine ausführlichere Darstellung findet sich in Hagemann, D., Lehrbass, F., 2018, S. 6 f.

⁶ Beispielsweise klassifiziert die Weltbank das Wohlstandsniveau aller Staaten in Abhängigkeit des BIP pro Kopf in „low-income“, „lower-middle-income“, „upper-middle-income“ und „high-income“.

⁷ Vgl. Cantor, R., Packer, F., 1996, S. 39.

⁸ Vgl. Afonso, A. et al., 2011, S. 4.

⁹ Vgl. Afonso, A., 2002, S. 9.

¹⁰ Vgl. Mellios, C., Paget-Blanc, E., 2006, S. 4.

¹¹ Vgl. Cantor, R., Packer, F., 1996, S. 39.

Formalisiert wird diese Determinante als quadrierte Abweichung der Inflationsrate vom Zielwert 2%.¹²

Staatsverschuldung in Relation zum BIP: Je höher die Verschuldung eines Staates ist, desto größer sind in der Regel die Zinslast und der Refinanzierungsbedarf und desto schwieriger ist die Bedienung der Schulden. Die Rückzahlungsfähigkeit hängt dabei auch vom Einnahmenpotenzial des Staates ab. Ab einer bestimmten Schuldenlast bewerten die Marktteilnehmer die Schuldentragfähigkeit als unzureichend und die Nachfrage nach Staatsanleihen sinkt.¹³

Haushaltssaldo in Relation zum BIP: Hohe Haushaltsdefizite eines Staates implizieren eine mangelnde Fähigkeit Einnahmen zu generieren oder eine unzureichende Ausgabenkontrolle.¹⁴

Bankensektor-Stressindikator: Neben der direkten Staatsverschuldung sind auch die Eventualverbindlichkeiten bei der Finanzlage eines Staates zu beachten. In diesem Zusammenhang ist insbesondere der heimische Bankensektor von Bedeutung, da oftmals eine gegenseitige Abhängigkeitsbeziehung zwischen dem Staat und den Banken besteht.

Nettoauslandsverschuldung in Relation zum BIP: Bei einer hohen Nettoauslandsverschuldung steigt die Gefahr, dass die in Fremdwährung denominierten Verbindlichkeiten einer Volkswirtschaft nicht mehr bedient werden können. Es besteht eine hohe Anfälligkeit für externe Schocks in Form von Kapitalabzügen und Währungsabwertungen.¹⁵

Leistungsbilanzsaldo in Relation zum BIP: Anhaltende Leistungsbilanzdefizite müssen durch Kapitalzuflüsse aus dem Ausland finanziert werden, sodass ceteris paribus die Auslandsverschuldung und die Abhängigkeit des öffentlichen und privaten Sektors von ausländischen Kapitalgebern ansteigen.¹⁶

Devisenreserven: Durch hohe Devisenreserven lassen sich sowohl Leistungsbilanzdefizite und Kapitalabzüge finanzieren als auch Währungsabwertungen stabilisieren.¹⁷

¹² Man kann diese Größe auch als Indikator für die Steuerbarkeit der Geldmenge durch die Zentralbank interpretieren.

¹³ Vgl. Rowland, P., Torres, J. L., 2004, S. 20.

¹⁴ Vgl. Afonso, A., 2002, S. 10 f.

¹⁵ Vgl. Afonso, A., 2002, S. 10.

¹⁶ Vgl. Cantor, R., Packer, F., 1996, S. 39.

¹⁷ Vgl. Afonso, A. et al., 2011, S. 5; Rowland, P., Torres, J. L., 2004, S. 21.

3 Empirische Auswertung

3.1 Ordered Logit-Modell

Das Modell basiert auf einer unbeobachteten latenten abhängigen Variablen y_i^* . Die latente Variable bestimmt sich aus den unabhängigen Variablen wie folgt:

$$y_i^* = \sum_{k=1}^K \beta_k x_{ik} + \varepsilon_i \quad (1)$$

Formel 1: Latentes Schätzmodell, Quelle: Eigene Darstellung in Anlehnung an Verbeek, M., 2017, S. 230

Dabei stellen x_{ik} die Ausprägungen der K in Abschnitt 2 identifizierten Risikofaktoren beim jeweiligen Staat i dar. Die Regressionskoeffizienten β_k messen den Einfluss der einzelnen Risikofaktoren auf die latente Variable. ε_i ist der logistisch verteilte Störterm.¹⁸

Aus der latenten Variablen y_i^* kann über die Schätzung von Klassengrenzen das Rating als beobachtete polytome Variable y_i zugeordnet werden. Zur trennschärferen Abgrenzung der Ratingklassen wird die Ratingskala von Moody's gemäß nachfolgender Zuordnung auf sieben Ratingstufen aggregiert:

Rating	Aaa	Aa1-Aa3	A1-A3	Baa1-Baa3	Ba1-Ba3	B1-B3	Caa1-C
Aggregierte Ratingeinstufung	G	F	E	D	C	B	A

Tab. 1: Aggregation der Ratingskala

¹⁸ Vgl. Verbeek, M., 2017, S. 230.

Daraus ergibt sich das Ordered Logit-Modell wie folgt:

$$y_i = \begin{cases} G & \text{falls } y_i^* > \mu_1 \\ F & \text{falls } \mu_1 \geq y_i^* > \mu_2 \\ E & \text{falls } \mu_2 \geq y_i^* > \mu_3 \\ D & \text{falls } \mu_3 \geq y_i^* > \mu_4 \\ C & \text{falls } \mu_4 \geq y_i^* > \mu_5 \\ B & \text{falls } \mu_5 \geq y_i^* > \mu_6 \\ A & \text{falls } y_i^* \leq \mu_6 \end{cases} \quad (2)$$

$$\text{mit } y_i^* = \beta_{GDPPC}x_{iGDPPC} + \beta_{GDPG}x_{iGDPG} + \beta_{UR}x_{iUR} + \beta_{INF}x_{iINF} + \beta_{DBT}x_{iDBT} + \beta_{FB}x_{iFB} + \beta_{FSI}x_{iFSI} + \beta_{NXD}x_{iNXD} + \beta_{CAB}x_{iCAB} + \beta_{FXR}x_{iFXR} + \varepsilon_i$$

Formel 2: Ordered Logit-Modell

μ bezeichnet dabei jeweils den Schwellenwert, der die Grenze zwischen den Ratingstufen festlegt. Die unbekannt Parameter in (1) und (2), d.h. die Regressionskoeffizienten β_k sowie die Schwellenwerte μ_1 bis μ_6 , werden über eine Maximum Likelihood-Schätzung bestimmt.

3.2 Datensatz und Datenaufbereitung

Die Ordered Logit-Regression wird auf Basis eines Querschnittsdatensatzes durchgeführt. Dafür werden die Ratings von Moody's und die volkswirtschaftlichen Kennzahlen von Moody's und Fitch für alle Staaten für das Jahr 2016 verwendet. Als Ratings werden die Long-Term-Foreign-Currency Ratings der jeweiligen Staaten gewählt. Die 124 betrachteten Ratings teilen sich wie folgt auf die aggregierten Ratingkategorien auf:

Ratingscore	G	F	E	D	C	B	A
Anzahl im Datensatz	12	13	16	16	20	37	10

Tab. 2: Ratingverteilung

Die Ratings von A bis C decken den Subinvestmentgrade-Bereich ab. Sie sind ausreichend gut besetzt für die noch folgenden, diesbezüglichen Modellprognosen. Die eingeführten Determinanten müssen durch konkrete Kennzahlen operationalisiert werden.

Die Operationalisierung erfolgt anhand nachfolgender Tabelle:

Determinante (vermutetes Vorzeichen)	Sym- bol	Definition	Quelle
BIP pro Kopf (+)	GDPPC	BIP pro Kopf aus 2016 in Tausend US-Dollar	Moody's
Reales BIP- Wachstum (+)	GDPG	Durchschnittliches jährliches reales BIP-Wachstum zwischen 2014 und 2016 in Prozent	Moody's
Arbeitslosen- quote (-)	UR	Durchschnittliche Arbeitslosenquote zwischen 2014 und 2016 in Prozent des Erwerbspersonenpotenzials	Fitch
Inflationsrate (-)	INF	Quadrierte Abweichung von 2 % bei der durchschnittlichen jährlichen Änderungsrate des Verbraucherpreisindex zwischen 2014 und 2016 in Prozentpunkten	Moody's
Staatsverschul- dung in Relation zum BIP (-)	DBT	Quotient aus Staatsverschuldung und BIP aus 2016 in Prozent	Moody's
Haushaltssaldo in Relation zum BIP (+)	FB	Durchschnittlicher Quotient aus Haushaltssaldo und BIP zwischen 2014 und 2016 in Prozent	Moody's
Bankensektor- Stressindikator (-)	FSI	Dummy-Variable, die den Wert „1“ annimmt, falls gemessen am Macro-Prudential Indicator eine mittlere bis hohe Wahrscheinlichkeit eines Systemstresses im Bankensektor vorliegt	Fitch
Nettoauslands- verschuldung in Relation zum BIP (-)	NXD	Quotient aus Nettoauslandsverschuldung und BIP aus 2016 in Prozent	Fitch
Leistungsbilan- saldo in Relation zum BIP (+)	CAB	Durchschnittlicher Quotient aus Leistungsbilanzsaldo und BIP zwischen 2014 und 2016 in Prozent	Moody's
Devisenreserven (+)	FXR	Kumulierte Devisenreservebestände der Zentralbank aus 2016 in Milliarden US-Dollar	Moody's

Tab. 3: Operationalisierung der Determinanten

3.3 Ergebnisse

Erkenntnisse über die Einflüsse der einzelnen Risikofaktoren und ihrer statistischen Signifikanz liefert die Schätzung des Ordered Logit-Modells.¹⁹ Die Ergebnisse der Schätzung sind in der nachfolgenden Tabelle dargestellt:

Risikofaktor (unterstellter Zusammenhang)	Koeffizient	Standardfehler	p-Wert
GDPPC (+)	0,1516	0,0225	<0,0001
GPDG (+)	0,0344	0,0893	0,7004
UR (-)	-0,0048	0,0243	0,8449
INF (-)	-0,0041	0,0018	0,0223
DBT (-)	-0,0216	0,0068	0,0015
FB (+)	0,1237	0,0707	0,0801
FSI (-)	-1,2540	0,4103	0,0022
NXD (-)	-0,0013	0,0027	0,6144
CAB (+)	0,0182	0,0307	0,5528
FXR (+)	0,0010	0,0006	0,0687
Schwellenwerte	Koeffizient	Standardfehler	p-Wert
F G	6,4287	1,0804	< 0,0001
E F	3,8548	0,8655	< 0,0001
D E	1,4897	0,6831	0,0292
C D	0,0399	0,6452	0,9506
B C	-1,3595	0,6648	0,0409
A B	-4,3447	0,8109	< 0,0001

Tab. 4: Schätzergebnisse Ordered Logit-Modell

Es zeigt sich, dass alle Koeffizienten die vermuteten Vorzeichen haben. Allerdings sind nicht alle Koeffizienten statistisch signifikant. Dies verdeutlichen die p-Werte.

¹⁹ Wir nutzen die R-Pakete ordinal und rms.

Fett hervorgehoben sind p-Werte unter 5%. Es zeigt sich, dass das BIP pro Kopf zum 0,1%-Niveau signifikant ist. Die Verschuldung in Relation zum BIP und der Bankensektor-Stressindikator sind jeweils zum 1%-Niveau und die Inflationsrate zum 5%-Niveau signifikant. Für eine ausführlichere Interpretation des Modells verweisen wir auf die Literatur.²⁰

3.4 Prognosequalität des Modells

Wie hoch die Prognosequalität des Modells in-sample ist, lässt sich anhand einer Konfusionsmatrix aufzeigen, in der die mittels des Modells prognostizierten Ratingscores den tatsächlichen Ratingscores gegenübergestellt werden:²¹

		Prognostizierter Ratingscore							Summe
		A	B	C	D	E	F	G	
Tatsächlicher Ratingscore	A	3	7	0	0	0	0	0	10
	B	3	30	3	1	0	0	0	37
	C	0	9	7	4	0	0	0	20
	D	0	3	4	6	3	0	0	16
	E	0	0	1	5	7	1	2	16
	F	0	0	0	0	5	4	4	13
	G	0	0	0	0	0	5	7	12
	Summe	6	49	15	16	15	10	13	124

Tab. 5: Konfusionsmatrix Ordered Logit-Modell in-sample

Insgesamt wurden auf den 2016er Daten 64 von 124 Ratingscores exakt vorhergesagt. Damit erzielt das Modell eine Hit Rate von 51,6%. Kein prognostizierter Ratingscore weicht um mehr als zwei Stufen vom Tatsächlichen ab. Eine Abweichung um mehr als eine Stufe tritt nur in 5,6% der Fälle auf.

²⁰ Eine ausführliche Interpretation findet sich in Hagemann, D., Lehrbass, F., 2018, S. 7 ff.

²¹ Ergänzend sei auf den p-Wert des Likelihood Ratio Tests hingewiesen. Die Teststatistik beträgt 162,19 und der resultierende p-Wert ist fast Null.

Speist man die Werte aus 2017 für die Regressoren ein, so ergibt sich die out-of-sample Prognosequalität wie folgt:

		Prognostizierter Ratingscore							Summe
		A	B	C	D	E	F	G	
Tatsächlicher Ratingscore	A	2	4	0	0	0	0	0	6
	B	2	35	4	0	0	0	0	41
	C	0	8	3	7	2	0	0	20
	D	0	3	4	6	3	0	0	16
	E	0	0	0	5	7	2	2	16
	F	0	0	0	0	5	4	4	13
	G	0	0	0	0	0	3	9	12
	Summe	4	50	11	18	17	9	15	124

Tab. 6: Konfusionsmatrix Ordered Logit-Modell out-of-sample

Insgesamt wurden out-of-sample 66 von 124 Ratingscores exakt vorhergesagt. Damit erzielt das Modell eine - leicht verbesserte - Hit Rate von 53,2%.

3.5 Logit-Modell

Besonders kritisch ist ein Wechsel zwischen Investmentgrade und Subinvestmentgrade. Wir ersetzen die bislang zu erklärende Variable "Ratingscore" durch eine binäre Variable namens "IG" und kodieren diese mit 0, falls ein Ratingscore von A bis C vorliegt und 1 sonst.

Die Schätzergebnisse sind wie folgt:²²

Risikofaktor (unterstellter Zusammenhang)	Koeffizient	Standardfehler	p-Wert
Konstante	-0,3477	1,8013	0,8469
GDPPC (+)	0,4491	0,1224	0,0002
GPDG (+)	0,2556	0,2248	0,2556
UR (-)	0,0568	0,0632	0,3690
INF (-)	-0,0576	0,0316	0,0683
DBT (-)	-0,0734	0,0273	0,0072
FB (+)	0,4916	0,1961	0,0122
FSI (-)	-2,6434	1,2522	0,0348
NXD (-)	-0,0012	0,0103	0,9108
CAB (+)	-0,0319	0,1225	0,7945
FXR (+)	0,0167	0,0063	0,0085

Tab. 7: Schätzergebnisse Logit-Modell

Die Inflation ist nicht mehr signifikant. Hingegen sind der Haushaltssaldo und die Devisenreserven als signifikante Risikofaktoren hinzugekommen.

²² Wir nutzen das R-Paket `logitf`.

Die Treffergenauigkeit hat sich verbessert:²³

		Prognose IG		
		0	1	Summe
Tatsächlicher Ratingscore	0	61	6	67
	1	5	52	57
	Summe	66	58	124

Tab. 8: Konfusionsmatrix Logit-Modell in-sample

Insgesamt erzielt das Modell eine Hit Rate von 91,1%.

²³ Ergänzend sei auch hier auf den p-Wert des Likelihood Ratio Tests hingewiesen. Die Teststatistik beträgt 128,4 und der resultierende p-Wert ist fast Null.

4 Prognosemodelle

Theoretisch könnte man die geschätzten Modelle zur Prognose verwenden, indem man aktuelle Attribute der Staaten einsetzt. Diese Informationen sind jedoch bereits an den Märkten verarbeitet und sollten sich zeitnah im aktuellen Rating der Staaten widerspiegeln.

Für ein Frühwarnsystem würde man hingegen Prognosen für die zukünftigen Werte der Regressoren benötigen. Daher ist es sinnvoll, die Anzahl der Regressoren zu reduzieren. Wir fokussieren uns deshalb im ersten Schritt auf die signifikanten Einflussgrößen (fett in Tabelle 7).

Bei den Regressoren des Logit-Modells fällt auf, dass die Devisenreserven (FXR) Aussagekraft besitzen. Diese sind im Regelfall schwer prognostizierbar, weil sie sich schlagartig durch Zentralbankentscheidungen ändern können.

Die übrigen Größen können jedoch gut prognostiziert werden. Prognosen für das BIP und Aussagen zur Stärke des Finanzsektors werden regelmäßig publiziert. Die Bevölkerungsanzahl ändert sich nicht schlagartig und die Planungen für die öffentlichen Haushalte sind der staatlichen Finanzplanung bzw. den Wahlprogrammen zu entnehmen.

4.1 Logit-Prognosemodell

Fortan nutzen wir daher nur die Regressoren GDPPC, DBT und FSI. Auf FB verzichten wir, weil dies eine stärker vergangenheitsorientierte Größe ist, deren aktueller Inhalt sich bereits in GDPPC und DBT widerspiegelt.²⁴

Risikofaktor (unterstellter Zusammenhang)	Koeffizient	Standardfehler	p-Wert
Konstante	-0,2850	0,5812	0,6239
GDPPC (+)	0,3074	0,0671	< 0,0001
DBT (-)	-0,0508	0,0138	0,0002
FSI (-)	-2,3141	0,8419	0,0060

Tab. 9: Schätzergebnisse Logit-Modell 2

²⁴ Zudem würde eine Hinzunahme die Hit Rate nicht erhöhen, wohl aber die Komplexität des Prognosemodells

Die Vorzeichen bleiben wie beim ersten Logit-Modell. Die Treffergenauigkeit hat sich in-sample leicht verändert:

		Prognose IG		
		0	1	Summe
Tatsächlicher Ratingscore	0	63	4	67
	1	10	47	57
	Summe	73	51	124

Tab. 10: Konfusionsmatrix Logit-Modell 2 in-sample

Das Modell erzielt nur noch eine Hit Rate von 88,7%, welche jedoch noch auskömmlich erscheint.

Speist man die Werte aus 2017 für die Regressoren ein, so ergibt sich die out-of-sample Prognosequalität wie folgt:

		Prognose IG		
		0	1	Summe
Tatsächlicher Ratingscore	0	60	7	67
	1	5	52	57
	Summe	65	59	124

Tab. 11: Konfusionsmatrix Logit-Modell 2 out-of-sample

Es ergibt sich eine out-of-sample Hit Rate von 90,3%.

4.2 Deep Learning-Prognosemodelle

Der Begriff "Deep Learning" bezeichnet Methoden des maschinellen Lernens. Selbige wurden bereits vor dem Jahr 2000 in Banken eingesetzt²⁵ und erfreuen sich auch aktuell großer Aufmerksamkeit.²⁶ Alternativ zum Logit-Modell soll nun mit einem klassischen Multilayerperceptron (MLP) und einem monotonen MLP

²⁵ Vgl. White, H., 1988, S. 451 ff.; Lehrbass, F., Volmer, R., 1997, S. 339 ff.

²⁶ Vgl. Cont, R., Sirignano, J., 2018, S. 1 ff.

gearbeitet werden.²⁷ Letzteres nutzt während des Trainingsvorgangs die bereits aus dem Ordered Logit-Modell erkennbaren monotonen Beziehungen zwischen den Regressoren und der Bonität.²⁸ Die Netzarchitektur wird auf zwei Schichten von "Hidden Neurons" begrenzt. Dies ist zugleich die Anzahl, ab der von "Deep Learning" gesprochen wird. Aus der Literatur ist bekannt, dass stetige Funktionen prinzipiell²⁹ mit einer, unstetige mit zwei Schichten approximiert werden können.³⁰

Beim Logit-Prognosemodell nutzen wir vier Modellparameter für drei Regressoren. Die Eingangsschicht (Layer) des MLP hat bereits vier Parameter.³¹ Wir verwenden in den beiden "Hidden Layers" nur jeweils ein Neuron.³² In Summe hat das Four-Layer-MLP somit $4 + 2 + 2 = 8$ Parameter. Von daher erwarten wir in-sample mindestens eine Treffergenauigkeit von 88,7%. Die MLP werden im Online-Modus mit dem Ziel der Minimierung des Mean Squared Errors trainiert.³³ Das klassische MLP erzielt eine Treffergenauigkeit von 91,9%, das monotone MLP nur 82,3%. Diese Ergebnisse ändern sich weder durch Hinzunahme eines zweiten Neurons auf den „Hidden Schichten“ noch durch diverse Methodenvariationen. Da das klassische MLP klar dominiert, werden nur seine Gewichte vorgestellt:

Risikofaktor (unterstellter Zusammenhang)	Gewicht
Bias	1,7199
GDPPC (+)	6,1557
DBT (-)	-1,5836
FSI (-)	-0,9141

Tab. 12: Lernergebnisse Input Schicht

²⁷ Vgl. Zhang, H., Zhang, Z., 1999, S. 1820 ff. Für eine Anwendung in der Stahlindustrie siehe Lang, B., 2005, S. 31 ff.

²⁸ So führt eine Erhöhung der Verschuldung in Relation zum BIP (DBT) zu einer Verschlechterung des Ratings. Dieser Zusammenhang dreht sich also nicht ab einem bestimmten Niveau um.

²⁹ D. h. bei einer entsprechend großen Anzahl an "Hidden Neurons". Vgl. Hand, D. J., Mannila, H., Smyth, P., 2001, S. 392. Es kann aber durchaus Gründe geben, trotzdem mit mehr als einer „Hidden Schicht“ zu arbeiten, z. B. besseres Lernverhalten.

³⁰ Vgl. Ripley, B. D., 1993, S. 41 ff.

³¹ Im KI-Jargon: 3 Inputweights + Bias.

³² Als Aktivierungsfunktion nutzen wir $\tan(0,5 x)$.

³³ Wir nutzen die R-Pakete neuralnet, nnet und monmlp.

Für die Zwischenschichten ergibt sich:

Input	Gewicht
Bias	0,2388
Inputneuron	5,0915
Bias	0,4935
Hidden 1	-0,8703

Tab. 13: Lernergebnisse Hidden Schicht

Die Treffergenauigkeit hat sich in-sample gegenüber dem Logit-Modell verändert.

		Prognose IG		
		0	1	Summe
Tatsächlicher Ratingscore	0	62	5	67
	1	5	52	57
	Summe	67	57	124

Tab. 14: Konfusionsmatrix Deep Learning-Modell in-sample

Das MLP erzielt eine Hit Rate von 91,9% in-sample. Wir ergänzen die out-of-sample Performance:

		Prognose IG		
		0	1	Summe
Tatsächlicher Ratingscore	0	55	12	67
	1	5	52	57
	Summe	60	64	124

Tab. 15: Konfusionsmatrix Deep Learning-Modell out-of-sample

Out-of-sample verringert sich die Hit Rate auf 86,3%. Es gibt somit keinen Anlass vom Logit-Modell zum MLP zu wechseln.

4.3 Fallstudie Italien

Nachdem in Italien nun eine gegenüber der Europäischen Währungsunion tendenziell „nicht-kooperative Regierung“ an die Macht gekommen ist, könnte diese den "too big too fail"-Status dahingehend ausnutzen, dass die ohnehin schon hohe Staatsverschuldung von 2,3 Billionen Euro weiter erhöht wird, um Wahlversprechen zu erfüllen.³⁴ Eine aus den Wahlprogrammen abgeleitete, denkbare Erhöhung wären 310 Milliarden Euro, womit sich eine Gesamtverschuldung von 2,6 Billionen Euro ergäbe.³⁵ Der Regressor DBT würde sich somit um 13% erhöhen. Den Regressor GDPPC belassen wir unverändert auf dem 2017er Niveau. Das Logit-Modell würde in diesem Fall weiterhin ein Investmentgrade-Rating vorhersagen (Vorhersagewert 0,88). Geht man jedoch davon aus, dass zusätzlich der Bankensektor-Stressindikator (FSI) von Null auf Eins wechselt, so sagt das Modell ein Abrutschen in den Subinvestmentgrade-Bereich voraus (Vorhersagewert 0,41). Dies ist nicht unrealistisch, da z. B. die Aktivseiten der Banken bei einem steigenden Spread für italienische Staatsanleihen leiden würden.³⁶

³⁴ Vgl. Heinemann, F., 2018, S. 2.

³⁵ Vgl. Sauer, U., 2018, S. 18.

³⁶ Zum Zeitpunkt der Erstellung des Artikels war es bereits zu einem solchen Spread-Anstieg gekommen.

5 Fazit und Ausblick

Die Modellergebnisse haben gezeigt, dass sich sowohl das konzipierte Ordered Logit- als auch das Logit-Prognosemodell gut zur Bestimmung und Vorhersage von Staatsratings bzw. zur Zuordnung eines Investmentgrade-Status eignen. Das Deep Learning-Modell erzielt zwar in-sample eine sehr gute Hite Rate, erweist sich out-of-sample jedoch nicht aussagekräftiger als das Logit-Modell. Die Schätzergebnisse zeigen, dass zur Vorhersage des Ratings insbesondere das BIP pro Kopf, die Staatsverschuldung in Relation zum BIP, die Wahrscheinlichkeit für einen Systemstress im Bankensektor sowie die Abweichung der Inflationsrate von einem stabilen Preisniveau von Relevanz sind. Bei der Investmentgrade-Zuordnung haben zudem der Haushaltssaldo und die Devisenreserven eine hohe Erklärungskraft. Diese Faktoren sollten bei der Bonitätsanalyse von Staaten daher genauer untersucht werden.

Auf Basis der vorgestellten Modelle und Ergebnisse lassen sich für unterschiedliche politische und wirtschaftliche (Stress-)Szenarien Auswirkungen auf die zukünftige Ratingeinstufung ableiten. Dies ist insbesondere vor dem Hintergrund der in den letzten Jahren weltweit zugenommenen Länderrisiken von hoher praktischer Bedeutung für das Risikomanagement in Banken und Unternehmen sowie für den Handel mit Staatsanleihen.

Literaturverzeichnis

- Afonso, A. (2002): Understanding the determinants of sovereign debt ratings: Evidence for the two leading agencies, Lissabon 2002
- Afonso, A., Gomes, P., Rother, P. (2011): Short and long-run determinants of sovereign debt credit ratings, in: International Journal of Finance and Economics, 16. Jg., Nr. 1, S. 1-15
- Bénassy-Quéré, A., Brunnermeier, M., Enderlein, H., Farhi, E., Fratzscher, M., Fuest, C., Gourinchas, P. O., Martin, P., Pisani-Ferry, J., Rey, H., Schnabel, I., Véron, N., Weder di Mauro, B., Zettelmeyer, J. (2018): Reconciling risk sharing with market discipline: A constructive approach to Euro Area reform, Center for Economic Policy Research - Policy Insight Nr. 91, London 2018
- Basel Committee on Banking Supervision (2017): The regulatory treatment of sovereign exposures, Basel 2017
- Cantor, R., Packer, F. (1996): Determinants and impact of sovereign credit ratings, in: Federal Reserve Bank of New York - Economic Policy Review, 2. Jg., Nr. 2, S. 37-53
- Cont, R., Sirignano, J. (2018): Universal features of price formation in financial markets: Perspectives from deep learning, Illinois 2018
- Hagemann, D., Lehrbass, F. (2018): Ein Ordered-Logit-Modell zur Erklärung von Staatsratings, in: Risiko Manager, Nr. 03/2018, S. 4-14
- Hand, D. J., Mannila, H., Smyth, P. (2001): Principles of data mining, Cambridge: Massachusetts Institute of Technology Press, 2001
- Heinemann, F. (2018): Ende der Naivität, in: Süddeutsche Zeitung vom 19.03.2018
- Lang, B. (2005): Monotonic multi-layer perceptron networks as universal approximators, in: Duch, W., Kacprzyk, J., Oja, E., Zadrozny, S. (Hrsg.): Artificial neural networks: Formal models and their applications - Proceedings of the International Conference on Artificial Neural Networks, Warschau 2005, S. 31-37
- Lehrbass, F., Volmer, R. (1997): Kohonens selbstorganisierende Karten und der Terminkontrakt auf den DAX, in: Wirtschaftsinformatik, 39. Jg., Nr. 4, S. 339-344
- Mellios, C., Paget-Blanc, E. (2006): Which factors determine sovereign credit ratings?, in: The European Journal of Finance, 12. Jg., Nr. 4, S. 361-377
- Ripley, B. D. (1993): Statistical aspects of neural networks, in: Barndorff-Nielsen, O. E., Jensen, J. L., Kendall, W. S. (Hrsg.): Networks and chaos - Statistical and probabilistic aspects, London: Chapman & Hall Verlag, 1993, S. 40-123
- Rowland, P., Torres, J. L. (2004): Determinants of spread and creditworthiness for emerging market sovereign debt: A panel data study, Bogotá 2004

- Sauer, U. (2018): Italien vor der Wahl - Das Geld fehlt, doch die Politiker geben immer neue Versprechen, in: Süddeutsche Zeitung vom 22.02.2018
- Verbeek, M. (2017): A guide to modern econometrics, 5. Aufl., Hoboken: John Wiley & Sons Verlag, 2017
- White, H. (1988): Economic prediction using neural networks: The case of IBM daily stock returns, in: Proceedings of the International Conference on Neural Networks, San Diego 1988, S. 451-459
- Zhang, H., Zhang, Z. (1999). Feedforward networks with monotone constraints, in: Proceedings of the International Joint Conference on Neural Networks, Washington D.C. 1999, S. 1820-1823

Überblick Schriftenreihe Bisher erschienene Bände



kostenloser Download
unter fom-ifes.de

- Cox, P. / Lehrbass, F. (2018): Determinanten der Replikationsgüte von Exchange Traded Funds, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 16, 2018, ISSN 2191-3366, ISBN 978-3-89275-407-7
- Lehrbass, F. / Scheipers, N. (2017): Determinanten der Höhe von Wirtschaftsprüfungshonoraren am Beispiel von gelisteten Unternehmen im Prime Standard, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 15, 2017, ISSN 2191-3366, ISBN 978-3-89275-406-0
- Schwarz, J. (2017): Ergebnisse der Analyse von Studienabbrüchen, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 14, 2017, ISSN 2191-3366, ISBN 978-3-89275-405-3
- Lehrbass, F. (2016): Risikomessung für den globalen Kohlehandel: Einfache und fortgeschrittene Verfahren nebst Backtesting sowie ein Vergleich mit IFRS 7, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 13, 2016, ISSN 2191-3366, ISBN 978-3-89275-404-6
- Godbersen, H. (2016): Die Means-End Theory of Complex Cognitive Structures – Entwicklung eines Modells zur Repräsentation von verhaltensrelevanten und komplexen Kognitionsstrukturen für die Wirtschafts- und Sozialwissenschaften, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 12, 2016, ISSN 2191-3366, ISBN 978-3-89275-403-9
- Seng, A. / Landherr, G. (2015): Vielfalt leben und Vielfalt gestalten – Diversity Management in der Lehre, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 11, 2015, ISSN 2191-3366, ISBN 978-3-89275-402-2

- Gansser, O. A. / Schutkin, A. (2014): Studie zur Validierung der Persönlichkeitsmerkmale Abenteuerlust und Routineverhalten, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 10, 2014, ISSN 2191-3366, ISBN 978-3-89275-401-5
- Gansser, O. A. (2014): Marketingplanung als Instrument zur Krisenbewältigung, in: Krol, B. (Hrsg.), ifes Schriftenreihe, Band 9, 2014, ISSN 2191-3366, ISBN 978-3-89275-400-8
- Runia, P. M. / Wahl, F. / Rüttgers, C. (2013): Das Markenimage von Hersteller- und Handelsmarken: Eine empirische Analyse der Imagekomponenten von Körperpflegemarken auf der Grundlage eines Markenidentitätskonzeptes, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 8, 2013, ISSN 2191-3366
- Naskrent, J. / Rüttgers, C. (2013): Sportmonitor Essen 2013: Eine empirische Analyse über das Image regionaler Sportvereine und ihre Sponsoring- und Promotionangebote, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 7, 2013, ISSN 2191-3366
- Seng, A. / Fiesel, L. / Rüttgers, C. (2013): Akzeptanz der Frauenquote, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 6, 2013, ISSN 2191-3366
- Naskrent, J. / Rüttgers, C. (2012): Wahrnehmung von Werbung mit Sportereignisbezug: Eine empirische Analyse der Einschätzung von Sponsoring und Ambush-Marketing im Rahmen der Fußball-Europameisterschaft und der Olympischen Spiele im Jahr 2012, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 5, 2012, ISSN 2191-3366
- Seng, A. / Fiesel, L. / Krol, B. (2012): Erfolgreiche Wege der Rekrutierung in Social Networks, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 4, 2012, ISSN 2191-3366
- Heinemann, S. / Krol, B. (2011): Nachhaltige Nachhaltigkeit: Zur Herausforderung der ernsthaften Integration einer angemessenen Ethik in die Managementausbildung, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 2, 2011, ISSN 2191-3366
- Hermeier, B. / Rettig, P. / Krol, B. (2010): Marken- und Produktmanagement durch Nutzung von Sportgroßereignissen: Möglichkeiten und Grenzen für Industrie und Handel, in: Krol, B. (Hrsg.), KCS Schriftenreihe, Band 1, 2010, ISSN 2191-3366

ISBN (Print) 978-3-89275-411-4

ISSN (Print) 2191-3366

ISBN (eBook) 978-3-89275-412-1

ISSN (eBook) 2569-5355



Institut für Empirie & Statistik
der FOM Hochschule
für Ökonomie & Management

FOM Hochschule

FOM. Die Hochschule. Für Berufstätige.

Die mit bundesweit über 50.000 Studierenden größte private Hochschule Deutschlands führt seit 1993 Studiengänge für Berufstätige durch, die einen staatlich und international anerkannten Hochschulabschluss (Bachelor/Master) erlangen wollen.

Die FOM ist der anwendungsorientierten Forschung verpflichtet und verfolgt das Ziel, adaptionsfähige Lösungen für betriebliche bzw. wirtschaftsnahe oder gesellschaftliche Problemstellungen zu generieren. Dabei spielt die Verzahnung von Forschung und Lehre eine große Rolle: Kongruent zu den Masterprogrammen sind Institute und KompetenzCentren gegründet worden. Sie geben der Hochschule ein fachliches Profil und eröffnen sowohl Wissenschaftlerinnen und Wissenschaftlern als auch engagierten Studierenden die Gelegenheit, sich aktiv in den Forschungsdiskurs einzubringen.

Weitere Informationen finden Sie unter fom.de

ifes

Das ifes verfolgt das Ziel, empirische Kompetenzen an der FOM zu bündeln und die angewandte Forschung im empirischen Bereich der Hochschule weiter voranzutreiben.

Drei Aufgabenbereiche bilden die Schwerpunkttätigkeiten: Zum einen unterstützt das ifes-Team die Hochschullehrenden der FOM bei der Kompetenzentwicklung im Bereich der empirischen Forschung und gewährleistet damit eine stetige Qualitätssicherung und die Einhaltung der Leitlinien der guten wissenschaftlichen Praxis im Rahmen von Forschungs- und Entwicklungsprojekten.

Zum anderen führt das ifes das Monitoring einer Zielgruppe von Berufstätigen im Rahmen von »FOM fragt nach«-Projekten durch. Im Rahmen dieser Projekte werden junge, berufstätige Leistungsträger/-innen mit Managementorientierung zu aktuellen ökonomischen Themen befragt, die teilweise als Panelbefragungen angelegt sind. Dadurch ist ein vielschichtiger Erkenntnisgewinn über eine in den nächsten Jahren stärker in die unternehmerische Verantwortung gehende Generation möglich.

Darüber hinaus nimmt das ifes eine zentrale Stellung im Bereich der Entwicklung und Unterstützung der Methodenausbildung in der Lehre der Bachelor- und Masterstudiengänge sowie im Promotionsprogramm der FOM ein.

Weitere Informationen finden Sie unter fom-ifes.de



Unter dem Titel »FOM forscht« gewähren Hochschullehrende der FOM Einblicke in ihre Projekte. Besuchen Sie den Blog unter fom-blog.de