
Márton Eifert / Dr. Janis Bauer / Dr. Franz-Rudolf Brüggemann

Machine Learning im Credit Management

**Nachrichtenbasierte Risikofrüherkennung
mittelständischer Unternehmen**



Risikofrüherkennung im Credit Management

Ein umfassender und aktueller Einblick in die Bonitätsentwicklung eines Kreditnehmers ist essenziell für ein effizientes, vorausschauendes Credit Management. Neben der statischen, oftmals lediglich turnusmäßigen Bonitätsbeurteilung, zum Beispiel bei der Vertragsgestaltung eines Kredit- bzw. Finanzierungsgeschäfts oder dessen Neuprüfung, ist auch die kontinuierliche Überwachung (Monitoring) notwendig. Ziel dabei ist es, frühzeitig auf Verwerfungen und Schieflogen des Schuldners – etwa mit einer Intensivierung der Kreditbetreuung oder Anpassungen von Limiten – reagieren zu können.

Mit den Themen Kreditrisiko und Rating beschäftigen sich die Experten bei der Münchener Firma *RSU Rating Service Unit GmbH & Co. KG* (kurz: *RSU*) bereits seit ihrer Gründung im Jahr 2004. Ziel war es damals und ist es noch heute, die methodischen und technologischen Kompetenzen der deutschen Landesbanken zu zentralisieren und mit einem gemeinsamen Datenpool Synergien in der Entwicklung von Rating-Modellen zu heben. Seit der ersten kommerziellen Lösung LB-Rating als Ergebnis dieser Kooperation, entstanden über die Jahre mehrere eigenständige Produkte – so auch Risk Guard, welches seit 2012 als marktdatenbasierte Frühwarnplattform im Einsatz ist. Ihre webbasierten Tools betreibt die RSU zentral und verantwortet auch die methodische Validierung und Weiterentwicklung.

Zu den bisherigen Kunden der RSU zählen neben Banken auch institutionelle Investoren und Versicherungen, die durch die Ratinginformationen sowie durch ein laufendes Monitoring bei der Portfolioselektion unterstützt werden.

Die methodischen Ansätze im Kontext der Kreditrisikomodellierung haben ein zentrales Ziel: Mittels statistischer Verfahren des *Machine Learning* wird versucht, Kreditnehmer anhand von Mustern in historischen Kennzahlen in gute (zahlungsfähige) und schlechte (zahlungsunfähige) Schuldner einzuordnen. Solche Kennzahlen basieren klassischerweise auf Bilanz- oder Marktdaten. Angesichts der

hohen Datenfrequenz eignen sich Marktdaten wie Aktienkurse, CDS-Spreads, usw., die in der Regel täglich verfügbar sind und bei denen – liquide Märkte vorausgesetzt – die Erwartungshaltung der Marktteilnehmer für die Zukunft bereits eingepreist ist, besonders gut zur Früherkennung von Zahlungsausfällen oder Downgrades bei Ratingagenturen. Allerdings geht dies mit der Einschränkung einher, dass diese Daten nur für wenige, vornehmlich börsennotierte und damit eher große Unternehmen (gemessen an Umsatz, Bilanzsumme, Mitarbeiteranzahl) zur Verfügung stehen. Dagegen sind Bilanzdaten zwar für deutlich mehr Unternehmen vorhanden und verwertbar, jedoch mit geringerer Frequenz und in der Regel mit einer zeitlichen Verzögerung von mehreren Wochen bis Monaten. Dadurch sind diese Daten zwar grundsätzlich für Ratingverfahren, nicht jedoch zur Frühwarnung geeignet.

Wie steht es aber um die Frühwarnung bei der Mehrheit der Unternehmen, insbesondere in Deutschland, die nicht an einer Börse gelistet sind, jedoch als kleinere und mittlere Unternehmen (KMU) den sogenannten *Mittelstand* bilden?

Häufig handelt es sich hierbei um inhabergeführte Familienunternehmen, die nicht selten die deutlich höheren Transparenzanforderungen des Kapitalmarkts scheuen, gleichzeitig aber als „Hidden Champions“, also als Weltmarktführer in Nischenmarktsegmenten, den Motor der Wirtschaft bilden. Regelmäßige Informationen wie Marktdaten sind hier also nicht verfügbar.

Nachrichtenbasierte Frühwarnung

Eine alternative Datenquelle, die eine hinreichend hohe Frequenz und Aktualität auch für den Mittelstand aufweist, stellen Zeitungsnachrichten dar: Seit 2018 führt die RSU eine Kooperationspartnerschaft mit der Firma *GBI-Genios Deutsche Wirtschaftsdatenbank GmbH*¹ (kurz: *Genios*) aus München, im Rahmen derer die einzigartigen Datenpools aus Ratinginformation (RSU) mit Nachrichten der deutschen Presselandschaft (*Genios*) kombiniert wurden, um daraus ein Frühwarnmodell für eine sich abzeichnende Bonitätsverschlechterung von Einzelunternehmen zu entwickeln. Seit 2019 ist dieses Modell nun auch in Risk Guard unter dem Namen „Nachrichtenbasierte Frühwarnung“ (kurz NBF) verfügbar und als Zusatzpaket lizenzierbar.

Das von Genios für die Entwicklung und den Produktivbetrieb bereitgestellte Datenarchiv umfasst derzeit mehr als 13 Mio. Nachrichtenartikel aus insgesamt

1 GBI-Genios Deutsche Wirtschaftsdatenbank GmbH mit Sitz in München ist eine Tochter der Frankfurter Allgemeinen; Zeitung und der Handelsblatt Media Group.

270 Zeitungsquellen ab dem Jahr 2005 zu etwa 30.000 Unternehmen mit Sitz in Deutschland. Täglich kommen in Risk Guard bis zu ca. 5.000 neue Zeitungsartikel hinzu.

Die Verteilung der Nachrichten nach Unternehmen bzw. nach Nachrichtenquellen sind in den Abbildungen 1 bzw. 2 dargestellt.

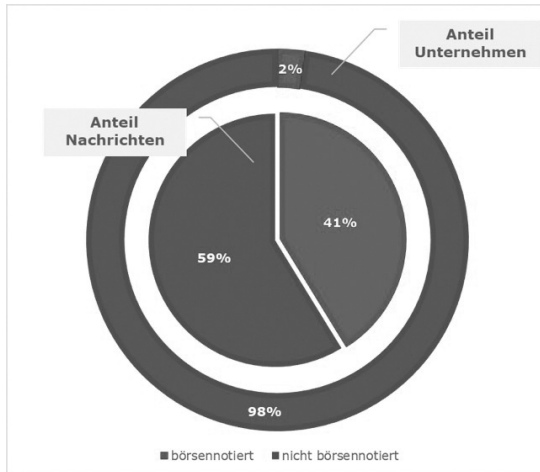


Abbildung 1: Nachrichtenabdeckung nach Unternehmen

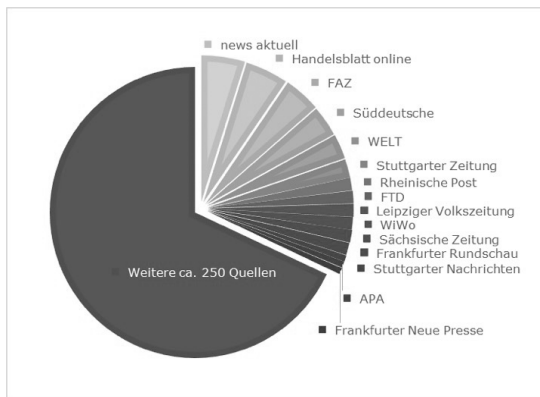


Abbildung 2: Nachrichtenabdeckung nach Zeitungsquelle

Von allen 30.000 zugeordneten deutschen Unternehmen sind nur etwa 700 börsennotiert (2 Prozent), bei den übrigen 29.300 Unternehmen (98 Prozent) handelt es sich um nicht gelistete Firmen. Dass auf wenige große Aktiengesellschaften knapp zwei Fünftel (41 Prozent) aller Artikel entfallen, ist nicht weiter überraschend. Gleichzeitig wird aber in fast 60 Prozent der übrigen Nachrichtenartikel von den nicht gelisteten Unternehmen, zu denen im Wesentlichen der deutsche Mittelstand gehört, berichtet.

Die 15 größten der 270 deutschen Zeitungen tragen etwa jeden dritten Artikel (ca. 4 Mio.) zum Bestand bei. Zwei Drittel der Nachrichten stammen aus kleineren Nachrichtenhäusern, darunter auch Zeitungen mit starkem regionalen Fokus wie etwa der Nordkurier (0,7 Prozent), die Frankenpost (0,3 Prozent), oder die Magdeburger Volksstimme (0,2 Prozent), um nur drei Beispiele zu nennen.

Diese – für die Anwendung in der Kreditrisikofrüherkennung – neue Art von Daten, die im Gegensatz zu (quantitativen) Markt- oder Bilanzdaten in einer sogenannten „unstrukturierten Form“ vorliegen, erfordert ein zusätzliches Repertoire an Methoden und Herangehensweisen, um diese überhaupt maschinell zu verarbeiten und sinnvolle Erkenntnisse hieraus gewinnen zu können.

Wie die RSU konkrete Lösungen für diese Herausforderungen entwickelt hat, wird im Folgenden kurz skizziert.

Methodik

Die „Good News“ von den „Bad News“ zu unterscheiden – damit beschäftigt sich die sogenannte Sentiment-Analyse als Teilbereich des Natural Language Processing (NLP). Hierbei werden aus Textinhalten mittels Machine Learning-Verfahren die zugrunde liegenden Stimmungsbilder extrahiert.

Oftmals ist aber je nach Anwendungsfall nicht jeder Text gleichermaßen relevant, hat also für den untersuchten Zweck keine Aussagekraft. Um aus dieser unüberschaubaren Menge diejenigen Texte zu identifizieren, aus denen überhaupt Erkenntnisse gewonnen werden können, ist eine Vorverarbeitung und Filterung erforderlich (Preprocessing):

Tägliche und automatisierte Verarbeitung

Bevor der eigentliche Textinhalt eingelesen und beispielsweise nach Fremdsprachen bereinigt wird, ist festzulegen, welche Bestandteile eines Dokumentes neben dem Textinhalt noch verwertet werden sollen (zum Beispiel Ressort, Titel, Untertitel, usw.) und welche nicht (zum Beispiel Autor, Bilder, URLs, usw.).

Vorsortierung nach Relevanz

In einem zweiten Schritt müssen die Textdaten nach inhaltlicher Relevanz gefiltert werden, deren Definition je nach Anwendungsfall variieren kann. Für die nachrichtenbasierte Frühwarnung der RSU lag es nahe, dass vor allem Wirtschaftsnachrichten als relevant betrachtet wurden. Bei anderen Nachrichten ist – zumindest für diesen Zweck – keine hohe Aussagekraft hinsichtlich bonitätsrelevanter Information zu einem Unternehmen zu erwarten: Man nehme das Interview mit einem ehemaligen bayerischen Ministerpräsidenten, der über seine Leidenschaft für Produkte des schwäbischen (leider insolventen) Modellbahnherstellers *Märklin* berichtete. Ein solcher Artikel erscheint tendenziell eher im Bereich „Politik“, „Feuilleton“ oder „Panorama“, nicht in „Wirtschaft“ oder „Finanzen“.

Nun könnte man einfach nach bestimmten Ressorts der Zeitungen filtern und alle anderen unberücksichtigt lassen. Allerdings sind diese Kategorien sehr ungenau und unvollständig, so dass man Gefahr läuft, zu viele Nachrichten pauschal zu verlieren, da gerade zum Beispiel im Lokalteil auch viele relevante Artikel, gerade zu kleinen Betrieben, stehen können.

Zu diesem Zweck wurde ein eigenes statistisches Klassifikationsverfahren entwickelt, um sicherzustellen, dass prinzipiell alle Ressorts berücksichtigt werden können: So wird aus dem Ressort „Wirtschaft“ fast kein Artikel herausgefiltert, aus anderen wiederum bleiben nur noch einzelne Nachrichten übrig, wie zum Beispiel Artikel über die Fußball-Übertragungsrechte im Pay-TV (Ressort „Sport“), die Trends auf den Absatzmärkten der Automobilhersteller („Motor“) oder die wirtschaftlichen Entwicklungen von Verlagen („Kultur“).

Als hierfür geeignete Klassifikationsverfahren kommen beispielsweise *Support Vector Machines* (SVMs) in Frage, die mit großen Datenmengen ebenso wie mit mehreren hundert Faktoren umgehen können, aber auch neuronale Netze. Dabei wurde dem Modell in historischen Daten anhand eines zuvor festgelegten Lexikons „antrainiert“, welche Texte Wirtschaftscharakteristika aufweisen und welche nicht. Dieses Lexikon wurde einmalig im Rahmen der Entwicklung aus hunderten bis tausenden solcher selektierter *Schlüssel- oder Signalwörter* gebildet, die teils typisch (etwa „Ebit“, „Marge“, „Verkauf“), teils explizit atypisch (etwa „kulinarisch“, „Außenstürmer“) für Wirtschaftsnachrichten sein können. Bei diesem sogenannten Bag-of-Words Ansatz erfolgt die Wahl dieser Wörter auf Expertenbasis, gestützt durch statistische Signifikanztests.

Identifikation von Unternehmen

Wurden alle nicht relevanten Nachrichtenartikel aussortiert, müssen aus den verbleibenden Texten betroffene Unternehmen erkannt und extrahiert werden. Hier kommen moderne Ansätze des Deep Learning (ein Unterbegriff des Machine Lear-

ning) zum Tragen. Mit einem eigens trainierten neuronalen Netz wird aus bekannten Mustern in und um Wortfolgen herum mit hoher Präzision erkannt, dass es zum Beispiel beim Textausschnitt „... sorgten bei *Linde* zu einem Umsatzrückgang ...“ um einen Konzern geht und nicht um eine Baumgattung. Somit wird für jeden Artikel eine Liste von gefundenen Unternehmensnamen extrahiert (auch *Named Entity Recognition* genannt).

Ein gegebener Nachrichtentext muss jedoch nicht für jedes darin genannte Unternehmen von zentraler Bedeutung sein: Zum Beispiel wird im Zusammenhang mit der Insolvenz von „Air Berlin“ von einer Jobmesse berichtet, auf der auch „Zalando“ und die „Deutsche Bahn“ ihre Stände eröffnet haben. Wird der Newstext gleichzeitig allen drei Unternehmen zugeordnet, hat dies womöglich gar fatale Auswirkungen auf das Bonitätsmonitoring einzelner Fälle, so dass hier im Zweifel eher konservativ vorgegangen werden muss. Daher werden die gefundenen Unternehmensnamen in einem nächsten Schritt nach ihrer sogenannten „Salienz“ sortiert und gefiltert. Dieses Ranking wird mit Hilfe leicht interpretierbarer Metriken wie etwa der Häufigkeit oder der Verteilung des Firmennamens im Text u. ä. gebildet. Unternehmen unterhalb einer bestimmten (absoluten und relativen) Salienz, hier „Zalando“ und „Deutsche Bahn“, wird der Artikel nicht mehr zugeordnet.

Nun hat das Verfahren zwar erkannt, dass es sich bei „Linde“ in einem bestimmten Kontext um einen Unternehmensnamen handelt. Ob dabei die „Linde PLC“ oder der „Linde Verlag“ gemeint ist, wird in einem abschließenden Schritt mit einem zentralen Firmenregister abgeglichen. In diesem Register sind Firmennamen in verschiedenen Schreibweisen erfasst, in denen auch zum Beispiel Unternehmensformen wie „AG“ bzw. „Aktiengesellschaft“ abgekürzt, ausgeschrieben oder gänzlich weggelassen werden.

Risikoscore und Frühwarnsignale

Der oben beschriebene *Bag-of-Words* Ansatz funktioniert nicht nur bei der Unterscheidung zwischen Wirtschaftsnachrichten und „Nicht-Wirtschaftsnachrichten“, sondern ebenso auch bei der Einteilung von Artikeln in die genannten Kategorien „drohender Zahlungsausfall“ bzw. „Kein drohender Zahlungsausfall“. Die Ausfallinformation wurde im Rahmen der Entwicklung für etwa 3.200 deutsche Unternehmen aus dem LB-Rating-Pool mit den Nachrichten kombiniert. Hierfür wurde ein eigenes Lexikon gebildet, ähnlich der Vorgehensweise für die Wirtschaftsklassifikation: Auf Basis der Vorkommen dieser Wörter bzw. Wortgruppierungen (z. B. „Schieflage“, „rote Zahlen“, „Verlust“ für negative Nachrichten oder „Absatzrekord“, „verdienen“, „feiern“ für positive Nachrichten) wird für jeden Nachrichtenartikel ein Risikoscore berechnet, der angibt, ob es sich insgesamt

eher um *Good News* oder um *Bad News* handelt. Je höher der Score, desto höher die Wahrscheinlichkeit für einen Zahlungsausfall aus dem Nachrichtentext und umgekehrt. Überschreitet der Risikoscore einen kritischen Grenzwert, wird jedes Unternehmen, welches dem Text zugeordnet werden konnte, mit einem Signal als auffällig gekennzeichnet. Das Niveau dieser Signalschwelle wurde so gewählt, dass mit einer Vorlaufzeit von bis zu einem Jahr etwa 75 Prozent aller Ausfälle in der LB-Rating-Datenhistorie erkannt werden, während gleichzeitig die Quote der Unternehmen mit mindestens einem Fehlalarm möglichst gering – in unserem Fall ca. 25 Prozent – bleibt.

Blick in die Anwendung

Als Ergebnis hat die RSU zwei nachrichtenbasierte Modelle entwickelt: News Score und News Sentiment Index – die in Risk Guard Warnsignale für auffällige Unternehmen senden und im Folgenden kurz vorgestellt werden.

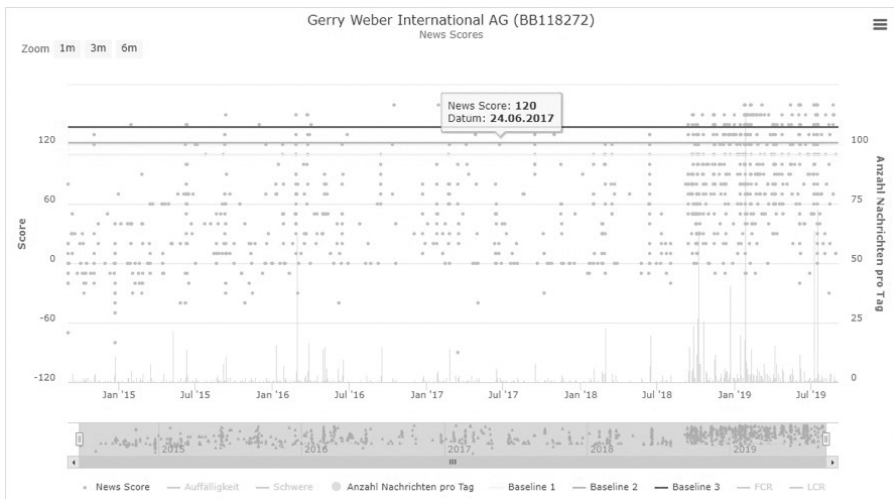


Abbildung 3: Chart des News Scores Modells



Abbildung 4: Chart des News Sentiment Index Modells

News Scores: Für jede Nachricht zu einem Unternehmen wird wie oben beschrieben ein Risikoscore berechnet. In der Anwendung sind alle täglichen Scores zu allen Nachrichten der letzten fünf Jahre im Chart dargestellt (vgl. grüne Punkte in Abbildung 3).

News Sentiment Index: Risikoscores der Einzelnachrichten werden durch „Glättung“ zu einem Sentiment Index aggregiert. In der Anwendung wird je Unternehmen der historische Verlauf des Sentiment Index der letzten fünf Jahre grafisch dargestellt (vgl. grüne Linie in Abbildung 4).

Beide Modelle können jeweils unabhängig voneinander ein Warnsignal für auffällige Nachrichten generieren, wenn mind. ein Score- oder der Sentiment Index-Wert die jeweils modellspezifische, kritische Schwelle überschreitet: Die gelben, orangenen bzw. roten Linien in den Abbildungen 3 bzw. 4 stellen für das jeweilige Modell die Signalschwellen für je eine Signalzone dar.

Für jedes Unternehmen ermöglicht Risk Guard außerdem einen Überblick über die aktuellsten Nachrichten bei Klick auf einen Score- bzw. Sentiment Index-Wert im Chart (vgl. Abbildung 5).

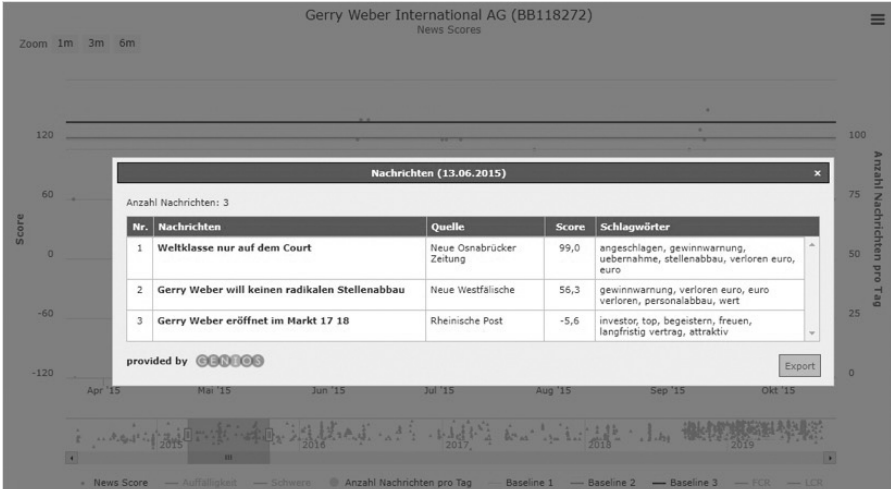


Abbildung 5: Überblick über die aktuellsten ins Modell eingehenden Nachrichten mit individuellem Risikoscore

Das sich öffnende Pop-Up-Fenster enthält einen ersten nachvollziehbaren Überblick über die Hintergründe, warum das betrachtete Unternehmen auffällig ist oder nicht: Neben Nachrichtentitel und -quelle wird der Einzelscore dargestellt sowie die sieben stärksten Schlagwörter, auf die das Modell „anschlägt“.

Bei Klick auf die einzelne Zeile im Pop-Up wird der jeweilige Artikel zudem zur Volltextansicht in einem zugriffsgeschützten Bereich von Genios bereitgestellt.

Fazit

Im Credit Management wird es zunehmend wichtiger – aber dank moderner statistischer Verfahren und des breiten Spektrums an Datenquellen auch leichter –, kontinuierlich ein möglichst umfassendes und aktuelles Bild über die Bonitätssituation seiner Kreditnehmer zu erlangen.

Die RSU hat 2019 die Abdeckung ihres Frühwarnsystems Risk Guard erweitert. Da zuvor ausschließlich börsennotierte Unternehmen überwacht werden konnten, zu denen es Marktdaten gab, war man bei nicht gelisteten und somit kleineren und mittelgroßen Unternehmen – im Mittelstand – mangels Datenquellen und geeigneter Verfahren auf die manuelle und zeitaufwändige Recherche durch Analysten angewiesen.

Dank der Kooperation mit GBI-Genios können nun Zeitungsnachrichten als neue Informationsquelle genutzt werden. Für diese neue Form von Datenquelle hat die RSU moderne Ansätze des *Machine Learning* und des *Natural Language Processing (NLP)* angewendet und eigene Verfahren entwickelt, um nun über Unternehmen potenziell jeder Größe effizient, zeitnah und zuverlässig Erkenntnisse zu gewinnen.