


Industry INSIGHTS

Künstliche Intelligenz im Kreditmanagement -
Möglichkeiten und Grenzen



Welche Anwendungsgebiete
ergeben sich für Künstliche
Intelligenz im Kreditmanagement?
Was sind die Herausforderungen
und wie können Unternehmen
profitieren?

Künstliche Intelligenz im Kreditmanagement - Möglichkeiten und Grenzen

Die Künstliche Intelligenz erlebt seit einiger Zeit einen gewissen Hype in den Medien. Auf vielen Gebieten erhofft man sich dadurch einen höheren Automatisierungsgrad oder bessere Entscheidungen. Diese Ansätze sind nicht neu. Bereits in den 1990er Jahren gab es hohe Erwartungen, die dann allerdings der Ernüchterung wichen, die aufgrund der erzielten Ergebnisse eintrat. Was ist nun anders und warum werden generell tiefgreifende Veränderungen erwartet? Daran schließt sich natürlich die Frage an, ob dieses auch für das Kreditmanagement gilt.

1. STATUS QUO

Betrachtet man die allseits sichtbaren Fortschritte in der Automatisierung, so sind insbesondere die Ansätze zur Bilderkennung und zum Textverstehen zu nennen, bei denen eine breite Nutzergruppe die Weiterentwicklung und die gesteigerte Leistungsfähigkeit von Systemen in unterschiedlichen Anwendungsgebieten wahrnimmt. Dieses geht mit drei Entwicklungen einher, die für diese Anwendungsgebiete besonders ausgeprägt sind:

- ✓ Es stehen umfangreiche Datenbestände zur Verfügung, mit denen Systeme trainiert werden können. Bei den Sprachanalyse tragen die Aufzeichnungen von Sprachassistenten dazu bei, bei der Bildanalyse Verschlagwortungen von Bildern in entsprechenden Portalen, wie z. B. Instagram. Der sich ausbreitende Einsatz von Sensoren, das „Internet of Things“, sorgt ebenso in bestimmten Anwendungsgebieten für eine breite Datenbasis wie die Aufzeichnung des Nutzerverhaltens im Internet.
- ✓ Die Rechnerleistung hat sich in den letzten zwei Dekaden noch einmal massiv erhöht. Dieses führt zur massiven Beschleunigung beim Training von Systemen. Damit werden sowohl Entwicklungszeiten für KI-Lösungen deutlich reduziert als auch erst umfangreiche Trainingszyklen auf großen Datenbeständen mit sehr vielen unterschiedlichen Datenfeldern als Ausgangssituation möglich.
- ✓ Schließlich gibt es mittlerweile mächtige Werkzeuge in der Form von Standardsoftware oder Toolboxen, mit denen KI-Lösungen entwickelt werden können. Die Entwickler sind so nicht mehr in der Situation, dass sie selber erst die Werkzeuge ent-

wickeln müssen, um dann damit eine Anwendung zu erstellen. So wird es auch einfacher, alternative Werkzeuge zu testen oder Parameter des Werkzeugs einfach zu verstellen und an den jeweiligen Anwendungsfall bestmöglich anzupassen.

2. ENTWICKLUNGEN DER KI

Betrachtet man die derzeitigen Publikationen, so werden insbesondere Künstliche Neuronale Netze und diese speziell in der Ausprägung des Deep Learnings genannt (LeCum et al. 2015). Ein zweites besonders beachtetes Feld ist Machine Learning. Insgesamt ist das Methodenspektrum in der Künstlichen Intelligenz aber wesentlich weiter. Beispielhaft seien folgende Themen genannt (Ertel 2016):

- ✓ Aussagen- und Prädikatenlogik
- ✓ Expertensysteme
- ✓ Suche und Spieltheorie
- ✓ Schließen mit Unsicherheit
- ✓ Maschinelles lernen und Data Mining
- ✓ Lernen durch Verstärkung (Reinforcement Learning)
- ✓ Künstliche Neuronale Netze mit einer Spezialform Deep Learning
- ✓ Mustererkennung

Beim Maschinellen Lernen werden aus Trainingsdaten statistische Modelle aufgebaut, mit denen versucht wird, Muster in den Lerndaten zu erkennen, um so die von diesen Mustern abgeleiteten Erkenntnisse zu verallgemeinern. Diese Lösungen können damit beispielsweise aus Datenmustern bei einem Kreditkartenbetrug statistische Verallgemeinerungen generieren, die dann bei einem neuen Fall, der ein ähnliches

Muster aufweist wie gelernte Betrugsfälle, auch auf einen potentiellen Betrug hinweist. Weitere Einsatzgebiete sind die Sprach- und Bilderkennung. Beim Maschinellen Lernen kann zwischen symbolischen Systemen, z. B. der Aussagenlogik, und Neuronalen Netz-basierten Ansätzen unterschieden werden. Letztere sollen hier im Mittelpunkt stehen. Dabei gibt es eine Vielzahl unterschiedlicher Netztypen, die jeweils aufgabenspezifisch konfiguriert werden müssen (Wiedmann, Buckler 2001). In der Grundstruktur sind Neuronen als Basisrechenoperatoren mit ihren Transferfunktionen sowie die Verbindungen zwischen den Neuronen mit ihren Verbindungsgewichten zu unterscheiden. Um Neuronale Netze einsetzen zu können, muss eine Lernphase vorausgeschaltet werden. Dabei unterscheidet man zwischen einem überwachten Lernen und einem unüberwachten (selbstständigen) Lernen. Das überwachte Lernen hat das Ziel, auf der Basis von Inputwerten auf den Output zu schließen (von unabhängigen Variablen auf abhängige Variable). Typisch dafür sind Prognosemodelle (von den Unternehmenskennzahlen z. B. auf die zukünftige Bonität schließen). Dazu muss bei dem Trainingsprozess versucht werden, den vom Netz erzeugten Output mit dem erwünschten Output abzugleichen. Dazu werden für die entsprechenden Trainingsläufe Korrekturfunktionen eingesetzt, die die auftretenden Abweichungen reduzieren. Die bekanntesten Vorgehensweisen basieren auf Backpropagation-Ansätzen. Methoden des unüberwachten Lernens haben zum Ziel, Interdependenzen zwischen den Eingabedaten zu identifizieren. Es geht dabei um Cluster- oder Optimierungsverfahren, z. B. um die Aufgabe, eine Kundenklassifikation vorzunehmen. Dazu wird das Netz bzgl. einer Zielfunktion optimiert. Neuronale Netze stellen damit in vielen Bereichen Ergänzungen oder Erweiterungen zu statistischen Verfahren dar. Die Größe der Netze hängt von der Zahl der verwendeten Inputdatenfelder, des Umfangs der abzubildenden Muster oder des Umfangs der möglichen Interdependenzen oder Cluster ab. Bei konventionellen Neuronalen Netzwerken werden die Eingabedaten zumeist als normierte Vektoren angelegt. Dieses macht allerdings die Bilderkennung schwierig, da gleiche Objekte auf Bildern in unterschiedlicher Positionierung so nicht identifizierbar sind. Daher verwendet man dazu Strukturen, die auch Matrizen (z. B. Bildpixel) als Eingabeschicht verwenden. Dieses sind sogenannte Convolutional Neural Networks, die über mehrere Filter-Layer die Eingabeinformationen verdichten (Shuiwary et al. 2013). Mit

sogenannten Rekurrenten Neuronalen Netzen können durch verschiedene Rückkopplungen über Verbindungsgewichte auch sogenannte „Gedächtnisstrukturen“ aufgebaut werden (z. B. für Zeitreihendaten). Je nach Struktur kann man zwischen „Kurzzeitgedächtnis“ und „Langzeitgedächtnis“ unterscheiden. Dazu werden teilweise auch komplexere Netzwerkstrukturen zu Modulen zusammenschaltet. Solche Strukturen sind für die Spracherkennung, aber auch für Aktienkursprognosen im Einsatz. Die Ausführungen sollen andeuten, dass es umfassender Erfahrung in diesem Gebiet bedarf, den adäquaten Netztyp für die jeweilige Aufgabenstellung auszuwählen und dann erheblicher Aufwand notwendig ist, das Neuronale Netz problemadäquat zu konfigurieren.

3. ANWENDUNGSGEBIETE IM KREDITMANAGEMENT

Nachfolgend soll bei einer Einschätzung, wie weit KI-Verfahren geeignet sind im Kreditmanagement die Automatisierung zu erhöhen oder Entscheidungen zu verbessern, zwischen Dienstleistern für das Kreditmanagement und die Kreditmanagement anwendenden Industrie- und Handelsunternehmen differenziert werden. Diese Unterteilung basiert auf den notwendigen Datenbeständen, die verfügbar sein müssen, um entsprechende Systeme zu trainieren. Bei sehr großen Anwendungsunternehmen können auch so umfangreiche Datenbestände vorliegen, dass es möglich sein kann, Anwendungspotentiale, die für die Dienstleistungsbranche benannt werden, auch dort einzusetzen.

3.1 Anwendungsbereiche bei Dienstleistern

Dienstleister experimentieren mit KI-Verfahren vor allem bei der Bonitätsbeurteilung von Kunden. Zwei Aspekte sind dabei von Bedeutung. Neben den klassischen Informationen zur Bonitätseinschätzung aus Jahresabschlussdaten, Zahlungserfahrungen und Inkassoinformationen werden auch weitere Informationen über die Person oder das Unternehmen herangezogen, z. B. solche, die aus öffentlichen Quellen des Internets extrahiert werden. Damit ergibt sich insgesamt eine breitere Datenbasis zur Prognose und neben numerischen Datentypen werden auch Texte verwendet. Auf dieser Basis können klassifizierende Neuronale Netze trainiert werden, um ein Rating vorzunehmen. Der Einsatz kann dabei sowohl für Personenratings als

auch Unternehmensratings erfolgen (Schumann 2018, S. 70). Für ein überwachtes Lernen ist dazu ein Trainings- und Validierungsdatenbestand notwendig, der auch eine ausreichende Zahl an ausgefallenen Unternehmen enthält. Üblicherweise ist die Aufbereitung der Daten dabei mit erheblichem Aufwand verbunden, da zum einen analysiert werden muss, wie mit „missing Values“ in den Datenbeständen sinnvoll umgegangen wird. Zum anderen muss auch eine sinnvolle Portionierung der Daten in Trainings- und Testdaten erfolgen. Die dann bei den Tests festgestellten Gütemaße müssen sich dann in der laufenden Anwendung erst bestätigen.

Neben vollständigen Ratings können auch spezialisierte Ratings mit Ansätzen der Neuronalen Netze vorgenommen werden. Ein Beispiel dazu ist das Bilanzrating, das sich neben klassischen Regressionsansätzen auch mit Neuronalen Netzen entwickeln lässt. Will man dieses weiter fassen, so trainiert man die Systeme nicht nur auf Basis des um Wahlrechte normierten Zahlenmaterials, sondern man bezieht auch die textuellen Informationen aus dem Lagebericht und insbesondere zu den zukünftigen Entwicklungen des jeweiligen Unternehmens mit ein. Aufgrund der hohen Varianz bedarf es umfangreicher Trainingsdaten.

Damit kommt auch hier der Textanalyse eine zusätzliche Bedeutung zu. Voraussetzung ist, dass auch diese Daten digital vorliegen und das ein umfangreicher Textkorpus vorhanden ist, mit dem wertende Aussagen identifiziert und trainiert werden können.

Vereinzelt finden sich die dargelegten Ansätze schon seit längerem auch im praktischen Einsatz. Was neuere Entwicklungen betrifft, so sind insbesondere die Erweiterungen um Textdaten als vorgeschalteter Input sowie die Möglichkeit, aufgrund der Systemleistung und eingesetzten Tools einfacher lernen zu können, zu nennen.

Der Textanalyse kommt damit entsprechende Bedeutung zu. Ebenso können Textnachrichten aus verschiedenen Internetforen herangezogen werden, um zu überprüfen, ob sich für Unternehmen, für die ein Monitoring stattfinden soll, bonitätsrelevante Informationen finden lassen. Dazu werden Verfahren des Text Mining, z. B. mit Lernverfahren über Support Vektor-Maschinen gekoppelt. Ziel muss es dabei sein, nur

bonitätsrelevante Informationen automatisiert vorzulegen und andere Informationen auszufiltern. Auch hier gibt es erste, zumindest teilautomatische Anwendungen, die dazu Unterstützung leisten (Mengelkamp 2017).

Auch bei Inkassodienstleistern fallen vielfältige Daten an, mit denen man versuchen kann, den Inkassoprozess zielgerichteter und erfolgreicher zu steuern. Zum einen liegen Dokumentationen vor, Kunden mit welchem Profil, nach welchen Verfahrensschritten Zahlungen geleistet haben. Hier kann man versuchen, über das Kundenprofil (Merkmale des Kunden) eine auf das jeweilige Profil abgestimmte Inkassostrategie zu identifizieren. Ein entsprechendes Neuronales Netzwerk trainiert so erfolgreiche Inkassostrategien, jeweils zugeschnitten auf das Profil des jeweiligen Kunden.

Ähnlich, vom Datenmaterial etwas einfacher, ist es die Ansprachestrategie für überfällige Kunden festzulegen. Es wird ein Trainingsdatensatz gebraucht, der zum einen Profildaten der Kunden enthält und zum anderen Aufschluss darüber gibt, wie der Kundenkontakt bzgl. der Forderung stattgefunden hat und wie erfolgreich die Kontaktaufnahme über den jeweiligen Kundenkanal bzgl. der Zahlung war. Dabei sind mehrere Aspekte nicht zu unterschätzen: Welche Daten des Kundenprofils korrelieren mit den wirkungsvollen Maßnahmen bzgl. des Zahlungsverhaltens? Wie geht man mit Datensätzen um, bei denen die Kundenprofildaten nicht vollständig sind? Kommt man dennoch zu sachgerechten Ergebnissen? Schließlich ist auch zu klären, ob die nach Kundenansprache erfolgte Zahlung wirklich auf die Ansprache zurückzuführen ist oder ob der Kunde nicht sowieso gezahlt hätte.

Eine insbesondere im Online-Handel wichtige Funktion ist die Fraud Prevention (Raj und Portia 2011). Aufgrund des Verhaltens von Kunden soll dabei geklärt werden, ob eine betrügerische Absicht hinter dem Kauf steckt. Auch dazu muss es eine empirische Fallsammlung geben, aus der solche Aspekte abgeleitet werden können. Dabei sind nicht nur Bonitäten, Adressen und historisches Kaufverhalten im Vergleich mit dem aktuell zu beurteilenden Kauf von Bedeutung, es können z. B. auch die Zeit des Online-Einkaufs, das Suchverhalten auf dem Internet-Auftritt oder die Dauer, mit der sich der Kunde auf einzelnen Internet-Seiten bewegt, von Bedeutung sein. Wichtig ist es in

diesem Segment über ausreichende Fälle des Online-Handels zu verfügen, mit denen auch schnell neue Betrugsversuche identifiziert werden können. Entsprechende Systeme werden dann laufend nachtrainiert. Dabei kommen nicht nur Machine Learning-Verfahren zum Einsatz. Es kann auch eine Kombination mit regelbasierten Lösungen eingesetzt werden.

3.2 Anwendungsbereiche in Industrie und Handel

Die Kreditpolitik eines Unternehmens ähnelt sehr stark eines Regelwerkes, dass die Voraussetzungen, Vorgehensweisen und Richtlinien zur Vergabe, zur Kontrolle und zum Reduzieren oder Streichen von Kreditlimiten regelt. Derartige Regeln können in Regelwerken wissensbasierter Systeme abgebildet werden. Diese Regelwerke sind dann bei einer Änderung der Kreditpolitik ebenfalls anzupassen. Dieses ist ein mittlerweile etablierter Einsatz von wissensbasierten Komponenten. Erweiterungen gibt es in der Ausgestaltung und Verfeinerung solcher Wissensbasen sowie von Werkzeugen zur verbesserten Wartung, dem Monitoring oder der Veränderung der Wissensbasis. Insofern ist der Einsatz von KI-Elementen in bestimmten Bereichen des Kreditmanagements und der automatisierten Entscheidungsfindung nicht neu (Wegner 2004, S. 142 f.).

Auch beim Bestimmen von Kundenratings kommen Künstliche Neuronale Netze schon länger zum Einsatz. Sie werden als Alternative zu statistischen Verfahren genutzt. Dabei ist zu berücksichtigen, dass zu diesem Zweck ausreichendes Datenmaterial verfügbar sein muss. Darüber hinaus war es früher ausgesprochen schwer, die Ursachen für die Einschätzung durch ein Neuronales Netz zu bestimmen. Heute stehen für bestimmte Netztypen Werkzeuge zur Verfügung, mit denen auch eine Interpretation der erzielten Ergebnisse möglich wird und so den Betroffenen auch die Ursache für die maschinelle Einschätzung erklärt werden kann.

Die Ausfallprognose für den vorhandenen Forderungsbestand müsste eigentlich zu jeder Zeit abrufbar sein, auch müsste es für einen vorhandenen Auftragsbestand, für den noch keine Rechnung gestellt wurde, aufgrund der vorhandenen Kundendaten und damit auch verbundenen Erfahrungen möglich sein, Ausfallprognosen für den Auftragsbestand vorzunehmen.

Hier können evtl. Prognosemodelle, die mit Neuronalen Netzen entwickelt werden, die Vorhersagegüte steigern.

Für die Liquiditätsprognose und die damit verbundenen Treasury-Strategien kann es sinnvoll sein, Schätzungen des Zahlungseingangs bezogen auf den einzelnen Auftrag oder die einzelne Rechnung vorzunehmen. Dabei gibt es zwei Ansätze. Der erste prognostiziert auf Basis des Kundenzahlungsverhaltens und weiterer Kundendaten, ob sich das Kundenzahlungsverhalten verbessert, verschlechtert oder gleich bleibt. Beim zweiten Ansatz wird kundenindividuell, bei ausreichendem Datenmaterial für das Training eine Prognose abgegeben, wann konkret nach Rechnungsausgang die Zahlung des Kunden erfolgt. Dabei wird das Ziehen des Skontos genauso berücksichtigt, wie z. B. das permanente Zahlen nach Fälligkeit. Mit Ansätzen der Mustererkennung kann z. B. identifiziert werden, dass das Unternehmen immer in bestimmten Rhythmen, z. B. zum Monatsende Zahläufe ausführt. Daneben erkennt das System Veränderungen im Zahlverhalten und berücksichtigt diese. Evtl. kann auch auf der Basis einzelner Unternehmensdaten außerhalb des Kreditmanagements ein Rückschluss auf das Kundenzahlverhalten getroffen werden. Auch solche Daten können in Lernverfahren zum Erkennen von Zahlungsmustern und Zahlverhalten integriert werden.

In hoch automatisierten Kreditmanagement-Systemen werden Routineentscheidungen automatisiert vom System durchgeführt. Kreditentscheider werden immer dann eingeschaltet, wenn aufgrund der dem System übertragenen Kompetenzen und der Systemeinstellungen dieses erforderlich ist. Dazu werden systemgestützt Aufgaben für die Kreditentscheider erzeugt. Je nach Umfang des zu bearbeitenden Kunden- und Interessentenbestandes und abhängig von dem Umfang der Systemkompetenzen können so vielfältige Arbeitsaufträge zur personellen Abarbeitung erzeugt werden. Diese werden üblicherweise in sequenziellen Listen anwendungsgestützt verwaltet, die dann manuell mit Bearbeitungsprioritäten versehen werden können. Werden diese Prioritätszuordnungen und die realen Zeiten vom Anlegen der Aufgabe bis zu deren Bearbeitung dokumentiert, so ergeben sich Aufgaben- und Risiko-bezogene Datensätze, die die Abarbeitungspraxis anstehender To-Do-Listen widerspiegeln. Ist der Umfang dieser Datensätze umfänglich, so kann aufgrund verschiedener

Felder, die auch für die Wichtigkeit des Risikos Hinweise geben, versucht werden ein Neuronales Netz zu trainieren, dass aufgrund der unabhängigen Daten automatisch versucht, Prioritäten den Arbeitsaufträgen zuzuordnen. Die Sortierung der zu bearbeitenden Aufgaben nach Wichtigkeit würde damit von System übernommen werden, dass von einem Künstlichen Neuronales Netz gesteuert wird. In einem Folgeschritt könnte man sogar andeuten, dass dieses Netz auch aus Umpriorisierungen, die Mitarbeiter noch vornehmen, lernt und damit ein Stück weit adaptiv gestaltet werden kann. Dabei wäre zu überlegen, ob das adaptive Lernen als Systemkomponente bereitgestellt wird oder als externe Lösung erfolgt.

Mit Chatbots kommunizieren Systemnutzer in natürlicher Sprache. Solche Bots werden heute eingesetzt, um im Massengeschäft Online-Fragen zu beantworten. Eine typische Zielrichtung ist dabei die Entlastung eines Call Centers. Chatbots basieren technisch auf Verfahren des Machine Learnings, Ansätzen der Künstlichen Intelligenz (auch Neuronales Netze) und der Sprachverarbeitung. Chatbots müssen einerseits aufgabenspezifisch sprachlich trainiert und andererseits in den inhaltlichen Kontext eingebunden werden. Dazu gilt es, eine Wissensbasis aufzubauen, in der die Informationen gespeichert sind, zu denen der Chatbot Auskunft geben soll. Mit Hilfe eines solchen Werkzeugs könnte z. B. ein Hilfetool für eine Kreditmanagement-Software erzeugt werden. Der Nutzer wäre so jederzeit in der Lage, Fragen zur Systemnutzung oder zum Kontext des Systems zu stellen, bspw. „Wie komme ich zu...“ „Wie kann ich ein Kreditlimit überschreiben“ oder auch „Wo finde ich Informationen zur...“. Dabei wäre es völlig unerheblich, in welchem Kontext sich der Anwender gerade bewegt.

Komplexer wäre der Ansatz, einen Chatbot einzusetzen, um vom System getroffene Entscheidungen zu erläutern. Dazu müsste eine Verbindung zur Regelbasis vorhanden sein, in der die Kreditentscheidungsprozesse abgelegt sind. Die jeweils getroffene Entscheidung wird jeweils mit den dabei geschlossenen Regeln dokumentiert. Dieses kann dann das System berechtigten Nutzern erläutern. Ebenso können Ratingentscheidungen erklärt werden. Insofern würde ein Chatbot in diesem Fall als mögliche Erklärungskomponente eingesetzt.

4. GRENZEN DES EINSATZES KÜNSTLICHER INTELLIGENZ

Ein wesentlicher Faktor beim Einsatz von Verfahren der Künstlichen Intelligenz insgesamt ist der notwendige Aufwand, der für das Gestalten der Wissensbasis oder das Aufbereiten und Trainieren von Künstlichen Neuronales Netzen als spezielle Form der Künstlichen Intelligenz aufgebracht werden muss.

Insbesondere beim Einsatz Neuronales Netze ist zu Beginn eines Projektes die notwendige Datenbasis kritisch zu prüfen. Dazu sind folgende Fragen zu beantworten:

- ✓ Ist die Zahl der verfügbaren Datensätze ausreichend?
- ✓ Gibt es bzgl. der evtl. zu treffenden Fallunterscheidungen jeweils eine ausreichende Zahl an Datensätzen zum Lernen? (z. B. auch Ausfalldaten?)
- ✓ Ist die notwendige Datenbreite verfügbar? Nur so wird man gegenüber konventionellen Verfahren Vorteile erzielen.
- ✓ Häufig stellt man bei Datensätzen fest, dass diese nicht vollständig sind. Oft finden sich „Missing Values“ für einzelne Datenfelder. Es stellt sich daher grundsätzlich die Frage, wie vollständig besetzt die Datensätze sein müssen, damit sie verwendet werden können. Daneben ist bei Datensätzen mit fehlenden Werten, die in den Trainingsdatenbestand eingehen, zu prüfen, welche Ersatzwerte für die entsprechenden Datenfelder verwendet werden sollen.

Beim Einsatz von Neuronales Netzen ist die Konfiguration des Netzes genau zu prüfen. Zwar existieren grundlegende Regeln, welche Netztypen für welche Aufgabenstellung geeignet sind, allerdings ist die genaue Konfiguration des am besten geeigneten Netzes auszutesten. Es geht dabei um die Zahl der Neuronen, die Anzahl an Schichten oder auch die Gestaltung von Verbindungen. Dieses kann häufig nur mit aufwändigen Tests bestimmt werden.

Als ein Vorteil von Maschine Learning-Verfahren wird oft das automatisierte Weiterlernen genannt. Dabei ist grundsätzlich zu prüfen, ob es um überwacht oder

unüberwachtes Lernen geht und damit unabhängig von verprobten oder bestätigten Ergebnissen, womit überhaupt gelernt werden kann. Ebenso muss festgelegt werden, wann es sich bei neuen Ergebnissen um Ausnahmen oder Ausreißer handelt, die eigentlich nicht in den Lösungsraum einbezogen werden sollten (z. B. weil der personelle Entscheider auf Informationen zurückgegriffen hat, die in den Trainingsdatenbeständen nicht abgebildet sind) oder ob es Ergebniszuordnungen sind, die für das weitere Training eines Netzes Berücksichtigung finden sollen. Ebenso könnten dazu Mindestanzahlen an Entscheidungen, die auf ein solches oder ähnliches Datenmuster zurückgeführt werden können, festgelegt werden, um den Weiterlernprozess anzustoßen. Auch dabei müssen eigentlich empirische Untersuchungen im Vorfeld stattfinden, um die dazu notwendigen Größen festzulegen. Regelbasierte Systeme lassen sich, wenn die grundlegenden Entscheidungsregeln stabil sind, dagegen immer weiter verfeinern. So können differenziertere Entscheidungsmuster schrittweise entwickelt werden. Zu berücksichtigen ist dabei allerdings, dass solche regelbasierten Systeme, wenn ein bestimmter Umfang überschritten wird, sehr komplex und damit nur schwer wartbar werden können. Die Modularisierung solcher Regelbasen ist daher für die Wartungsprozesse besonders wichtig.

Schließlich ist immer sauber zu messen, wie gut das neue Entscheidungssystem im Vergleich zur alten Lösung ist. Dazu gilt es, Prognosen oder Entscheidungen für die gleichen Situationen auf identischem Datenmaterial zu vergleichen. Die Stabilität der Lösung muss ein weiteres Kriterium sein. Zu hinterfragen ist, ob auch im Dauerbetrieb Qualitätskennzahlen in gleicher Größe erreicht werden, wie bei einer Validierung. Schließlich ist zu prüfen, ob sich im laufenden Betrieb wirklich Verbesserungen einstellen. Hier kann es sein, dass z. B. auch Laufzeitprobleme oder die direkte Datenverfügbarkeit den Einsatz erschweren oder sogar unpraktikabel machen. Schließlich muss der Aufwand zum Trainieren und Einstellen sowie Integrieren der Künstlichen Neuronalen Netze im Vergleich zum Ertrag, zur höheren Automatisierung oder zur verbesserten Entscheidungsqualität, gesehen werden.

Grundsätzlich ist anzumerken, dass Vieles, was heute unter Künstlicher Intelligenz verkauft wird, eigentlich konventionelle Algorithmen enthält und mit diesen

gemacht wurde. Schaut man sich viele Lösungen an, so stellt man fest, dass häufig Regressions- oder Clusteranalysen sowie Prognosemodelle aus Statistikpaketen genutzt werden, die mit den modernen Toolboxes allerdings anders verpackt daherkommen. Bei konkreter Betrachtung wird klassische Statistik anders benannt eingesetzt, führt aber dadurch manchmal zu Entscheidungsunterstützung oder -vorschlägen, wo vielleicht bislang rein personell gearbeitet wurde.

5. ZUSAMMENFASSUNG

Methoden der Künstlichen Intelligenz in Anwendungen des Kreditmanagements sind grundsätzlich nichts Neues. Wissensbasierte Lösungen zum Abbilden der betrieblichen Kreditpolitik sind in verschiedenen Kreditmanagement-Lösungen seit längerem etabliert. Ebenso finden sich schon bewährte Beispiele, in denen Neuronale Netze zur Bonitätsbewertung von Unternehmen eingesetzt werden.

Neuere Entwicklungen, insbesondere durch die höhere Leistungsfähigkeit von Rechnersystemen und die Verwendung von mächtigen Tools zur Gestaltung Künstlicher Neuronaler Netze, führen nun dazu, dass der Umgang mit dieser Technologie einfacher und der verbundene Aufwand, solche Systeme einzusetzen, reduziert wird. Gleichwohl darf der Aufwand der notwendig ist, entsprechende Systeme zu trainieren, nicht unterschätzt werden. Ebenso muss jeweils kritisch geprüft werden, ob die notwendigen Daten wirklich verfügbar sind, um die Lernverfahren angemessen einzusetzen. Ist dieses der Fall, so werden sich einzelne Einsatzbereiche ergeben. Allerdings wird davon auszugehen sein, dass insbesondere aufgrund der Beschränkungen bei den verfügbaren Daten der Einsatz vorwiegend bei Informationsdienstleistern stattfinden wird.

Daneben zeigt sich, dass durch weitere Aspekte, wie z. B. die differenziertere Abbildung von Kreditrichtlinien über entsprechende Anwendungslösungen, sich der Automatisierungsgrad im Kreditmanagement durchaus weiter erhöhen kann. Ebenso können verfeinerte Analysen und Auswertungen eine verbesserte Entscheidungsunterstützung für die Mitarbeiter im Kreditmanagement liefern.

Mehr unter

www.prof-schumann.de

LITERATUR

Ertel, W. (2016), Grundkurs Künstliche Intelligenz, 4. Aufl., Springer: Berlin – Heidelberg, 2016.

LeCun, Y., Bengio, Y. und Hinton, G. (2015), Deep Learning, Nature 521, S. 436 – 444.

Mengelkamp, A. (2017), Hinweise auf die finanzielle Stabilität von Unternehmen in Textdaten aus traditionellen und sozialen Medien – Eine vergleichende Fallstudie von Zeitungsartikeln und Tweets vor der Insolvenz der Schlecker e.K., in: van Koeverden, A., Schneider-Maessen, J., Schumann, M. und Weiß, B., Exzellenz im Credit Management – 15 Jahre BvCM e.V., Kleve, S. 27 – 38.

Raj, S. B. E. und Portia, A. A. (2011), Analysis on Credit Card Fraud Detection Methods, International Conference on Computer, Communication and Electrical Technology 2011, S. 152 – 156.

Schumann, M. (2018), Wie verändern Big Data, Künstliche Intelligenz und Blockchain das

Kreditmanagement?, in: van Koeverden, A., Schneider-Maessen, J., Schumann, M. und Weiß, B., Mit effektivem Credit Management gewappnet für die Herausforderungen der digitalisierten Zukunft, Kleve, S. 65 – 78.

Shuiwary, J., Wie, X., Ming, Y. und Kai, Y. (2013), 3D Convolutional Neural Networks for Human Action Recognition, IEEE Transactions on pattern analysis and machine intelligence (35,1), S. 221 – 231.

Wegner, G. (2004), Aktives softwareunterstütztes Kreditrisikomanagement mit dem Credit Application Manager, in: Schneider-Maessen, J., Schumann, M. und Weiß, B., Standortbestimmung im Credit Management, Economica: Augsburg, S. 131 – 148.

Wiedmann, K.-P. und Buckler, F. (2001), Neuronale Netze im Management, Gabler-Verlag: Wiesbaden

Wissen schafft Erfolg.



Prof. Schumann GmbH
Weender Landstr. 23
37073 Göttingen
Deutschland

+49 551 383 15 0
+49 551 383 15 20 (Fax)
info@prof-schumann.de
www.prof-schumann.de