

Automatische Mustererkennung zur Klassifikation von Konsumentenverhalten am Beispiel der Kreditwürdigkeitsprüfung

Vor dem Hintergrund der hohen Zahl an Insolvenzen, der steigenden Tendenz zur Überschuldung privater Haushalte und den hieraus resultierenden Forderungsausfällen hat die Bedeutung formalisierter Bonitätsanalyseverfahren für Banken und Unternehmen, insbesondere für Telekommunikationsanbieter und den Online- und Versandhandel, in den letzten Jahren zugenommen. Mathematisch-statistische Modelle und Methoden der Kreditwürdigkeitsprüfung (Kreditscoring) besitzen in wettbewerbsintensiven Märkten eine Schlüsselfunktion, da sie standardisiert und automatisiert die Abschätzung von Ausfallrisiken liefern und so zeitnah den Entscheidungsprozess über Genehmigung oder Ablehnung von Kreditanträgen oder Ratenkäufen unterstützen. Für Banken ergibt sich zudem aus den Richtlinien des Basler Ausschusses für Bankenaufsicht (Basel II) die Notwendigkeit, zu einer objektiven und nachvollziehbaren Abschätzung von Ausfallwahrscheinlichkeiten zu gelangen.

Allgemeine Beschreibung des Kreditscoring

Das Klassifikationsproblem der Kreditwürdigkeitsprüfung besteht in der Zuordnung eines neuen Kunden entweder zur Gruppe der kreditwürdigen oder der nicht kreditwürdigen Kunden. Zur Modellierung und Prognose des Zahlungsverhaltens können verschiedene statistische Verfahren in den Prozess der Kreditwürdigkeitsentscheidung integriert werden, z.B. die lineare Diskriminanzanalyse, Logit- und Probit-Modelle, nicht-parametrische Verfahren wie Entscheidungsbäume oder neuronale Netze als Lösungsansatz aus dem Bereich der künstlichen Intelligenz. Gängige Klassifikationsregeln minimieren dabei die Gesamtzahl falsch klassifizierter Objekte und gewichten so die beiden entstehenden Fehler (vgl. Abbildung 1) gleich. Da aber in der Praxis beide Fehler mit unterschiedlichen Kosten verbunden sind, bedarf es zur Beurteilung des aus einer Klassifikationsregel resultierenden, ökonomischen Risikos einer Gewichtung der Klassifikation mit Kosten. Eine Möglichkeit besteht darin, den Schwellenwert für die prognostizierte Ausfallwahrscheinlichkeit (Score), ab der ein Kunde als nicht

kreditwürdig einzustufen ist, anhand einer geeigneten Gewinn- bzw. Verlustfunktion, z.B. dem Deckungsbeitragszuwachs basierend auf dem Kostenverhältnis $C(1):C(0)$ mit $C(1) > C(0)$, festzulegen (vgl. Abbildung 2).

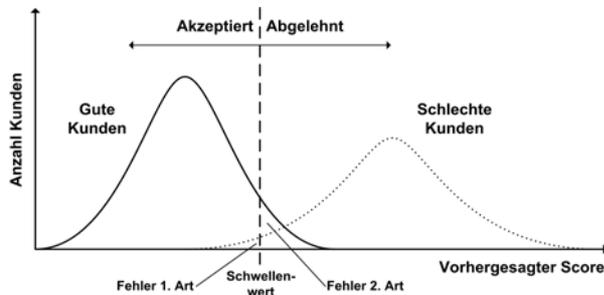


Abbildung 1: Klassifikationsfehler in der Kreditwürdigkeitsprüfung

Vorhergesagte Klasse \ Wahre Klasse	Nicht kreditwürdig	Kreditwürdig
Nicht kreditwürdig	$C(1)$: vermiedene Kosten und Verluste durch Ablehnung nicht kreditwürdiger Kunden	Fehler 1. Art
Kreditwürdig	Fehler 2. Art	$C(0)$: entgangener Gewinn als Opportunitätskosten durch Ablehnung kreditwürdiger Kunden (keine Fehler)

Fehler 1. Art: schlechter Kunde wird als kreditwürdig akzeptiert
Fehler 2. Art: guter Kunde wird als nicht kreditwürdig abgelehnt

Abbildung 2: Kostenbewertung der Klassifikation

Wird wie in Abbildung 3 ein bestimmter Deckungsbeitragszuwachs als Zielgröße festgesetzt, so ergeben sich zu unterschiedlichen Kostenverhältnissen verschiedene Schwellenwerte: für das Kostenverhältnis $C(1):C(0)=1:0.5$ können mehr Kunden akzeptiert werden (Schwellenwert 2) als für das Kostenverhältnis $1:1$ (Schwellenwert 1). Die Nicht-Berücksichtigung von realistischen Kosten in der Klassifikation führt also zu ökonomischen Fehlentscheidungen.

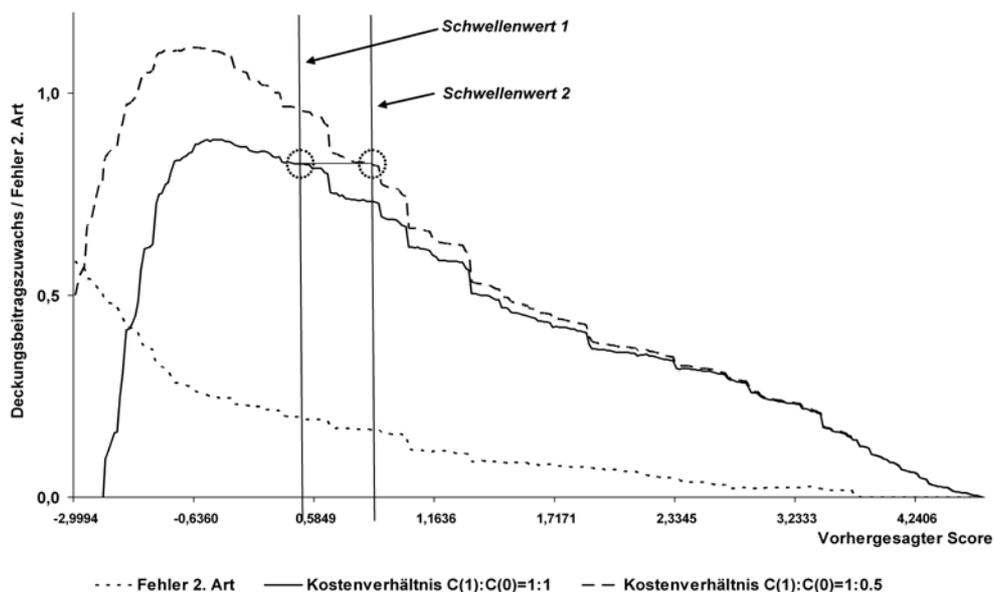


Abbildung 3: Kostenbewertung der Klassifikation für zwei beispielhafte Kostenverhältnisse

Einsatz von Techniken der Mustererkennung im Kreditscoring

Ein Scoring-Modell verwendet durchschnittliche oder auf eine bestimmte Art gewichtete Unterschiede zwischen kreditwürdigen und nicht kreditwürdigen Kunden bei bestimmten Kundenmerkmalen als Bonitätskriterien. Um das Zahlungsverhalten neuer Kunden vorherzusagen, werden die auf diesen Kriterien basierenden Klassifikationsregeln auf jeden neuen Kunden gleichermaßen angewendet. Dabei stellt sich jedoch die Frage, ob auf diesem Weg die Heterogenität der interessierenden Population hinreichend berücksichtigt wird. Beispielsweise diskriminiert bei Bonitätsprüfungen häufig das Merkmal Alter so stark, dass junge Kunden (bis 25 Jahre) als nicht kreditwürdig eingestuft werden. Dieses Ergebnis lässt sich statistisch durchaus rechtfertigen, da junge Menschen in Deutschland relativ zur Gesamtbevölkerung im Durchschnitt ein sehr schlechtes Zahlungsverhalten zeigen. An ein Kreditscoring muss aber im Hinblick auf die Kundenbindung und den damit verknüpften Unternehmenserfolg die Anforderung gestellt werden, auch aus den jüngsten Konsumenten die kreditwürdigen herauszufiltern. Als mögliche Lösung werden Techniken der automatischen Mustererkennung, wie z.B. selbstorganisierende Karten, herangezogen, um homogene Kundengruppen in einer Population zu identifizieren und so das Zahlungsverhalten lokal zu modellieren.

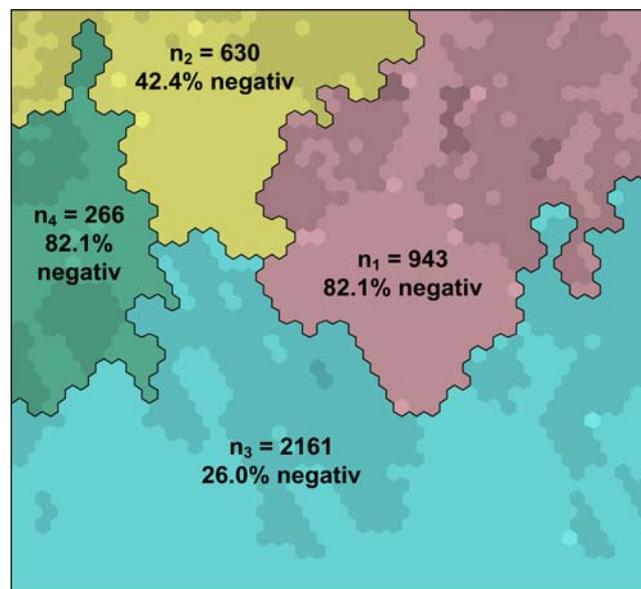


Abbildung 4: Selbstorganisierende Karte für Kunden eines Versandhandels

Eine selbstorganisierende Karte ist ein unüberwachtes neuronales Netzwerk, dessen Algorithmus die Ähnlichkeit der Kunden hinsichtlich ihrer Merkmale bewertet, entsprechend ähnliche Datensätze zusammenfasst und auf einer zweidimensionalen Karte abbildet. Die Beispielkarte in Abbildung 4 zeigt die Verteilung von 4000 Kunden eines Versandhandels, die

eine Ratenzahlung vereinbarten. Dabei fielen 41% der Zahlungen aus. Die erzeugte Karte besteht aus 1912 Objekten (Sechsecke), die jeweils bestimmte Kunden und ihre Merkmale repräsentieren. Hieraus werden vier größere Kundengruppen gebildet. Abbildung 5 zeigt die Verteilung der Kunden hinsichtlich ihrer Zugehörigkeit zur Gruppe der jüngsten Kunden. Dabei ist die Platzierung jedes Kunden auf jedem Merkmalsbild dieselbe.

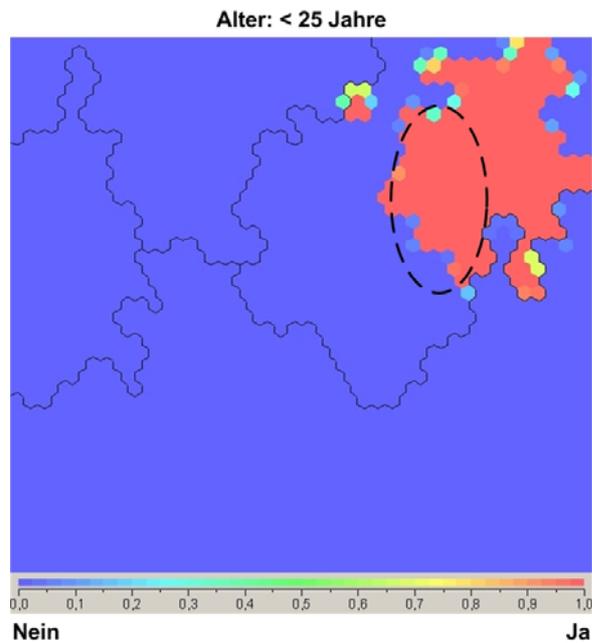


Abbildung 5: Merkmalsbild für das Kundenattribut „Alter: < 25 Jahre“

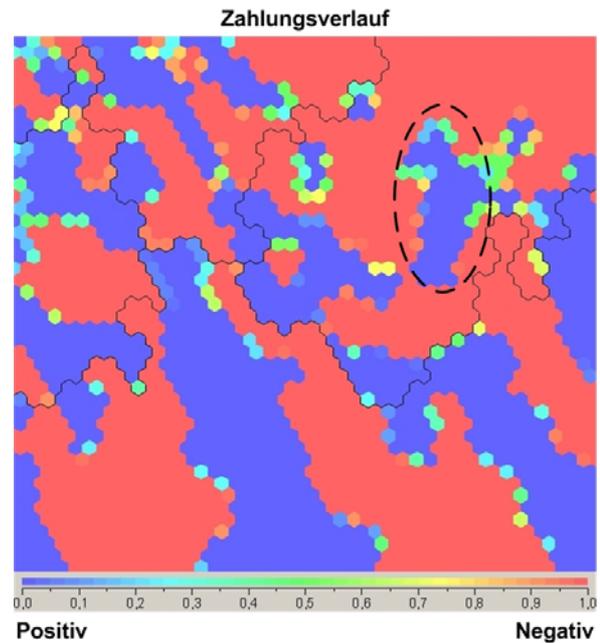


Abbildung 6: Merkmalsbild für das Kundenattribut „Zahlungsverlauf“

Die Anlage der Karte erfolgt ohne Berücksichtigung des tatsächlichen Zahlungsverhaltens, so dass der Algorithmus zur Prognose der Kreditwürdigkeit neuer Kunden, deren Zahlungsverhalten unbekannt ist, eingesetzt werden kann. Wird das Zahlungsverhalten zu deskriptiven Zwecken hinzugefügt (vgl. Abbildung 6), so wird deutlich, welche Merkmale und deren Kombinationen auf geringe Kreditwürdigkeit hindeuten. Gleichzeitig werden innerhalb der Kundengruppen mit hohem Ausfallrisiko (Markierung in Abbildung 6) auch Kunden identifiziert, die eine höhere Kreditwürdigkeit aufweisen. Unter Verwendung lokaler Prognoseverfahren werden in jeder der identifizierten Risikogruppen mit größerer Sicherheit diejenigen Konsumenten herausgefiltert, die kreditwürdig sind, als durch die bisher verwendeten gängigen Prognoseverfahren.

Fazit

In den bisherigen Untersuchungen zeigt sich, dass die beschriebene lokale Vorgehensweise insgesamt zu einer größeren Trennschärfe der kostenorientiert bestimmten Klassifikationsregeln führt. Im Weiteren sollen die lokalen Scoring-Verfahren insbesondere auf große Stichproben aus der Praxis angewendet werden, um ihre Eignung zur Analyse von Massendaten zu überprüfen.

Literatur

Schwarz, A., Arminger, G. (2005): Credit Scoring Using Global and Local Statistical Models. In: Weihs, C., Gaul, W. (Hrsg.): *Classification – the Ubiquitous Challenge*, S. 442-449, Springer (Heidelberg/Berlin), und die dort angegebene Literatur.