

Bayesianisches Kredit-Scoring

Eine innovative Idee zur Messung des Ausfallrisikos

Ein Beitrag von Markus J. Rieder

Einleitung

Die klassischen Methoden zum Kredit-Scoring sind großteils ausgereizt und deren Vor- und Nachteile den Anwendern in der Praxis satzsam bekannt. Neben der Tatsache, dass die Punkte in den Scorekarten kaum zu interpretieren sind, wird die klassische Statistik nicht damit fertig, dass die Scorepunkte bei kleinen Datenmengen große Schwankungen aufweisen und durch unterbestimmte Gleichungen die ganze Scorekarte instabil wird. Ausserdem ist es bei den klassischen Verfahren nur schwer möglich, das Wissen um die durchschnittliche Ausfallhäufigkeit einzubringen, und ein Re-Scoring von sich im Zeitablauf verändernden Beständen ist mit größerem Aufwand verbunden, als es nötig erscheint.

Von den Methoden der Bayesianischen Statistik hingegen ist bekannt, dass sie abzubilden imstande sind, was intuitiv klar erscheint, und dabei auch für kleine Datenmengen stabile Schätzer liefern (für eine Einführung in die Bayesianische Statistik siehe etwa Berry, 1996). Das wird durch Einbeziehen von Information erreicht, die bereits vor Analyse der Daten vorhanden ist (sogenannte *a priori* Information) – die Daten dienen dann

zur „Anreicherung“ dieser Vorinformation. Dieses Setup hat zum einen den Vorteil, dass auch qualitative Informationen zwanglos eingebracht werden können und erleichtert zum anderen das Neu-Analysieren von Daten, weil die Bayesianischen Verfahren sich aufgrund ihrer Updating-Relation für einen (zeit-)dynamischen Betrieb anbieten.

Aus dieser allgemeinen Einschätzung heraus wird evident, dass sich Bayesianische Verfahren zum Kredit-Scoring eignen. Die vorliegende Arbeit beschreibt ein solches Verfahren und vergleicht es auf der Basis von Antragsdaten aus dem Bereich selbständiger Gewerbekunden einer Retailbank mit den klassischen Verfahren.

Im zweiten Abschnitt werden kurz die wichtigsten klassischen Verfahren vorgestellt, der dritte Abschnitt zeigt, wie der Satz von Bayes zum Kredit-Scoring ausgebaut werden kann, worin seine Stärken bestehen, und dass die Bayesianische Statistik formal exakt auf eine vielfach vorgeschlagene Experten-Scorekarte führt. Im vierten Abschnitt wird das Verfahren einem Praxis-Test unterzogen, und im letzten Abschnitt zeigt die Zusammenfassung, dass die vorgelegte Methode imstande ist, die

sich traditionell gegenüberstehenden statistischen und expertenbefundenen Verfahren zu vereinen.

Klassische Verfahren des Kredit-Scorings

Die Methoden zum Kreditantrag-Scoring sind seit Anfang der 70er Jahre in der Theorie eingehend untersucht und in der Praxis umfangreich, vor allem zur Klassifizierung von Privatkunden, angewendet worden. Traditionell stehen sich dabei zwei Schulen gegenüber.

Prinzipielle Ansätze

Ein erster Ansatz zum Kredit-Scoring sind die expertenbasierten Verfahren. Diese basieren auf der Überzeugung von Kreditanalysten, bestimmte Risikotreiber aus ihrem ökonomischen Verständnis des Bedienens einer Finanzbelastung ableiten zu können. Dieses Wissen kann in Expertenkarten umgesetzt und damit zur Beurteilung eines Kredites genutzt werden.

Neben dem in quantitative Form gegossenen Expertenwissen der Kreditentscheider ist es die klassische Statistik, die als prinzipielle Zugänge vor allem Klassifikationsbäume und Regressionen vorgeschlagen hat, um das Wissen über historische Ausfälle in die Kreditvergabe einbeziehen zu können.

Die viel beschworene Unvereinbarkeit expertenbasierter versus statistischer Verfahren ist auf die Gegensätzlichkeit entlang zweier Dimensionen zurückzuführen. Zum einen ist das die Frage, ob ein Kredit individuell oder im Umfeld aller anderen Kredite gesehen wird. Die Expertenverfahren favorisieren sehr stark eine Einzelgeschäftssicht, wäh-

rendessen die Statistik sich ganz klar aus einer Portfolio-Sicht ableitet. Zum anderen scheinen die Expertenverfahren den statistischen Verfahren entgegenzustehen, weil erstere sich auf Kausalitäten berufen, wo letztere nur die Diskriminanz zwischen historisch guten und historisch schlecht gewordenen Krediten optimieren (Thomas, 2000).

Argumente in beiden Dimensionen fachen den Streit über einen „besten“ Zugang zum Kredit-Scoring immer wieder an. Der hier entwickelte Bayesianische Zugang zeigt, dass die beiden traditionellen Zugänge sich nicht ausschließen, sondern elegant in eine gemeinsame Form gegossen werden können.

Expertenkarten

Abseits eines statistischen Zuganges zum Scoring sind es Kreditsachbearbeiter selbst, die ihr Wissen und ihre Erfahrung bei der Kreditvergabe einbringen können. Dabei wird anhand sogenannter „Scorekarten“ versucht, Kreditnehmer gemäß ihrer Eigenschaften mit Punkten zu bewerten, wobei die gesamte Punkteanzahl einem Maß für die Bonität des Schuldners gleichkommt. Die Merkmale der Scoretabellen bilden ab, was die Kreditsachbearbeiter zur Beurteilung der Rückzahlungsfähigkeit fachlich für richtig und wichtig halten, und die Gewichtung der Punkte spiegelt wider, wie sehr die einzelne Merkmalsausprägung als bonitätssteigernd eingeschätzt wird.

Der Vorteil von Expertenkarten besteht darin, dass die vergebenen Punkte einfach zu verstehen sind und die tatsächliche Einschätzung der Kreditentscheider abbilden, was in dem meisten Fällen für hohe Akzeptanz sorgt. Die Schwäche des Verfahrens besteht darin, dass die Ex-

perten, welche das Punktesystem installieren, kaum die Abhängigkeit der einzelnen Merkmale untereinander zu berücksichtigen vermögen. Die Multivariabilität ist somit eliminiert, was sich in einer niedrigeren Performance dieser Systeme äußert.

Klassifikationsbäume

Unter Klassifikations- und Regressionsbäumen subsumieren sich Methoden, die mit Hilfe der bekannten Merkmale versuchen, die Grundgesamtheit aller Kreditnehmer vorab genau so in Teile zu schneiden, dass diese sich in ihrem Ausfallverhalten möglichst stark voneinander unterscheiden. Durch eine Reihe von Schnitten ist das Ziel der Verfahren also, Zerlegungen zu erhalten, die möglichst wenig bzw. möglichst viele der Ausfälle enthalten.

Ein Vorteil dieser Verfahren ist es etwa, dass ein und dasselbe Merkmal in mehreren Schnitten nutzbar ist und daher Nichtlinearitäten aufgelöst werden können. Ein Nachteil der Baumverfahren besteht dagegen darin, dass zu deren Kalibrierung sehr viele Daten (vor allem: sehr viele Ausfälle) zur Verfügung stehen müssen, da sonst die Statistiken nach nur wenigen Zerlegungen insignifikant werden. Im Falle zu weniger Zerlegungen wird das Verfahren auch zu „grobkörnig“, d.h. es können nicht ausreichend viele verschiedene Risikoklassen gebildet werden.

(Logistische) Regression

Die Regression, allen voran in der Form eines Logit-Modells, ist die am häufigsten anzutreffende statistische Methode im Kredit-Scoring. Dabei wird eine die Ausfallneigung kennzeichnende abhängige

Variable als Funktion einer gewichteten Summe der beschreibenden Merkmale modelliert. Ist diese Funktion die logistische Verteilung, so bezeichnet man das Modell als logistische Regression. Bei diesem Verfahren ist es nahe liegend, die abhängige Variable als Ausfallwahrscheinlichkeit zu interpretieren. Diese Interpretation hat sie mit den Klassifikationsbäumen und dem Bayesianischen Verfahren gemeinsam, was mit ein Grund für die Beliebtheit der logistischen Regression in der Praxis ist.

Vorteil eines stetigen Mappings auf die Ausfallwahrscheinlichkeit ist die theoretisch unendlich „feinkörnige“ Risikodifferenzierung. Die logistische Regression wird weiters geschätzt aufgrund ihrer Robustheit, die das Verfahren auch bei wenigen Daten anwendbar macht, und aufgrund der Verfügbarkeit der Rechenlogik in den statistischen Standard-Softwarepaketen. Nachteil der logistischen Regression sind die Schwierigkeiten, die mit der Interpretation der Regressionskoeffizienten verbunden sind. Die Gewichte der Scorekarten (Scorepunkte) sind in ihrer absoluten Höhe nur kaum zu interpretieren und schwierig zu kommunizieren, durch die Nichtlinearität der logistischen Verteilung entziehen sich auch die relativen Stellungen der Scorepunkte einer einfachen Deutung. In ihrer Anwendung im Zusammenhang mit einem Kredit-Scoring ist die logistische Regression auch nicht ohne Vorskalierung anwendbar, falls Ausfälle nur sehr unterrepräsentiert auftreten.

Bayesianisches Schließen

Satz von Bayes

Der Satz von Bayes eignet sich dazu, aus Daten Schätzungen über Zustände abzuleiten, ohne ein spezifisches Modell über das Verhältnis von Daten und Zuständen zu hinterlegen (Gelman et al., 1995). Mittels Bayesianischen Schließens kann eine (nicht-parametrische) Schätzgleichung aufgestellt werden, die die Wahrscheinlichkeitsverteilung der Zustände wiedergibt, wenn man die Daten kennt. Allgemein gilt

$$P(x \mid y) = P(y \mid x) * P(x) / P(y) \quad (\text{Gl. 1})$$

In obiger Gleichung ist x der Zustand, y die darüber gemessenen Daten. $P(x)$ ist die *a priori* Wahrscheinlichkeit, $P(y \mid x)$ die sogenannte Likelihood. Erstere spiegelt das Wissen wider, das man bereits vor dem Informationseintrag der Daten besitzt, letztere gibt an, wie sich die Daten verteilen, wenn ein bestimmter Zustand auftritt.

Anwendung auf das Kredit-Scoring

Wenn wir den Satz von Bayes als Updating-Relation verstehen, der eine Wahrscheinlichkeitsverteilung liefert, sobald *a priori* Wissen mit Daten ergänzt wird, so ist eine Anwendung auf das Kredit-Scoring zwanglos zu erhalten. Sei x das Merkmal „Ausfall“ mit den Ausprägungen „ja“ und „nein“, y der Satz der Kreditnehmer-Antragsdaten. Nach Bayes gilt demnach:

$$\begin{aligned} P(\text{Ausfall} \mid \text{Antragsdaten}) = \\ P(\text{Antragsdaten} \mid \text{Ausfall}) \quad (\text{Gl. 2}) \\ * P(\text{Ausfall}) / P(\text{Antragsdaten}) \end{aligned}$$

Die Interpretation, die sich aus diesem Satz anbietet, ist folgende: Einem gegebenen Kreditnehmer wird *a priori* unterstellt, dass er eine mittlere Ausfallwahrscheinlichkeit $P(\text{Ausfall})$ besitzt. Ausserdem weiß das Kreditinstitut aus der Historie, wie sich die Antragsdaten bei schlechten Kunden verhalten zu den Antragsdaten bei guten Kunden. Über die Antragsdaten, die er dem Kreditinstitut zur Verfügung stellt, offenbart der Kunde also zusätzliche Informationen über seine Ausfallneigung. Diese Zusatzinformation, $P(\text{Antragsdaten} \mid \text{Ausfall}) / P(\text{Antragsdaten})$, wird genutzt, um seine *a priori* Ausfallwahrscheinlichkeit zu „adjustieren“, und *a posteriori* $P(\text{Ausfall} \mid \text{Antragsdaten})$ zu ermitteln. Der Satz von Bayes sagt also, dass die Ausfallwahrscheinlichkeit proportional ist zum einen zur *a priori* Ausfallwahrscheinlichkeit, zum anderen zum Verhältnis der „schlecht gewordenen“ Antragsverteilung zur gesamten Antragsverteilung. Die Leistung des Bayesianischen Satzes besteht demnach darin, die Relation von Antrag zu Ausfall (die *Likelihood*) zu invertieren und konsistent mit dem *a priori* Wissen über Ausfall zu verknüpfen. Gleichung (2) gibt somit an, wie wahrscheinlich ein Ausfall ist, wenn bestimmte Antragsdaten vorliegen.

Die Zweistufigkeit des Verfahrens, nämlich vor Sichtung der Antragsdaten den allgemeinen Schätzer *a priori*-Verteilung zu haben, und diesen dann mittels *Likelihood* zu verfeinern, macht die Stärke des Verfahrens bei kleinen Datenmengen aus. Im Falle sehr stark gestreuter Antragsdaten üben diese über die Likeli-

hood wenig Einfluss auf die Schätzung der Ausfallwahrscheinlichkeit aus. Im Extremfall nicht vorliegender Antragsdaten wird immer noch ein stabiler Schätzer gewonnen – die *a priori*-Verteilung. Auch wenn daher die Anzahl der Fälle nicht überproportional groß ist im Vergleich zur Anzahl der Merkmale, lassen sich mittels Bayesianischer Verfahren noch robuste Schätzgleichungen ermitteln (Brown et al., 1999).

***A priori*-Verteilung**

Die Schätzung der *a priori*-Verteilung, $P(\text{Ausfall})$, ist eine Punktschätzung für die Zustände „Ausfall=ja“ und „Ausfall=nein“. Sie leitet sich von der langjährigen Erfahrung ab, mit wie vielen Ausfällen in einem bestimmten Kreditsegment im Mittel zu rechnen ist. Für das hier durchgeführte Beispiel beträgt die *a priori*-Wahrscheinlichkeit für „Ausfall=ja“ (die Ausfallwahrscheinlichkeit) 2%, die Wahrscheinlichkeit für „Ausfall=nein“ (die Überlebenswahrscheinlichkeit) 98%. Die Schätzwerte mögen sich von der buchhaltungstechnischen Größe Einzelwertberichtigung ableiten oder aus der Controlling-Größe Standardrisikokosten berechnet werden. Vielfach sind in den Kreditinstituten auch Historien über Ausfälle vorhanden, die ein gutes Bild darüber abgeben, mit wie vielen Ausfällen in Zukunft zu rechnen ist. Die Schätzung, wie viele Ausfälle im nächsten Jahr auftreten werden, ist aber auch durch Kreditsachbearbeitern leistbar – es ist keineswegs schlechter, auf deren Wissen zurückzugreifen und die mittlere Ausfallrate als *a priori*-Wahrscheinlichkeit zu benutzen.

Definiert man die *a priori*-Wahrscheinlichkeit als Parameter, so lässt sich später auch die Sensitivität gegenüber die-

ser Annahme prüfen oder die Annahme ganz eliminieren, indem man für einen gegebenen Kreditantrag angibt, wie sehr die Wahrscheinlichkeit für „Ausfall=ja“ von der Wahrscheinlichkeit für „Ausfall=nein“ abweicht (sog. odds-ratio).

***Likelihood*-Verteilung**

Die *Likelihood*-Verteilung $P(\text{Antragsdaten} \mid \text{Ausfall=ja})$ gibt an, wie wahrscheinlich die gegebenen Antragsdaten sind, wenn ein Ausfall vorliegt. Im Gegensatz dazu gibt $P(\text{Antragsdaten} \mid \text{Ausfall=nein})$ an, wie wahrscheinlich die gegebenen Antragsdaten sind, wenn kein Ausfall vorliegt. Beide Verteilungen lassen sich aus den historischen Kreditdaten ableiten oder gemäß einer Expertenschätzung eintragen. Die *Likelihood* hält also quantitativ fest, was ein Kreditsachbearbeiter *ex post* feststellen würde, wenn er heute einen ursprünglichen Antrag sieht, von dem inzwischen klar ist, dass er zu einem Ausfall gehört. Wenn etwa ein Kreditsachbearbeiter einen Ausfall mit den Worten „Schon wieder jemand unter 30 Jahren“ quittiert, ist das beispielsweise in einer erhöhten Wahrscheinlichkeit für das Merkmal *Alter* in der Ausprägung <30 wieder zu finden, gemessen daran, wie häufig die Ausprägung <30 überhaupt auftritt.

Technisch ist das Erstellen der Wahrscheinlichkeitsverteilung für Antragsdaten auf Basis bereits realisierter Ausfälle sehr einfach. Aus einer Historie von genügend vielen Ausfällen lässt sich ersehen, wie sich die Verteilung über die Antragsdaten realisiert. Mit $P(\text{Antragsdaten} \mid \text{Ausfall=ja})$ wird also abgeleitet, wie die Verteilung über die Merkmalsausprägungen ist, wenn es sich um einen Ausfall handelt. Demgegenüber zeigt die Größe $P(\text{Antragsdaten} \mid \text{Ausfall=nein})$, wie die

Verteilung der Antragsdaten aussieht, wenn es sich um einen gesunden Kreditnehmer handelt. Über die Relation der totalen Wahrscheinlichkeit,

$$\begin{aligned}
 P(\text{Antragsdaten}) = & \\
 & (P(\text{Antragsdaten} / \text{Ausfall=ja}) \\
 & * P(\text{Ausfall=ja}) \quad (\text{Gl. 3}) \\
 + & P(\text{Antragsdaten} / \text{Ausfall=nein}) \\
 & * P(\text{Ausfall=nein})
 \end{aligned}$$

ergibt sich aus obigen beiden *Likelihoods* und den beiden *a priori*-Verteilungen die multivariate Verteilung der Antragsdaten $P(\text{Antragsdaten})$. Diese gibt die Wahrscheinlichkeitsverteilung der Antragsdaten aller Kunden, guter wie schlechter, an. Die Bayesianische Scorekarte ergibt sich, indem man (Gl. 2) und (Gl. 3) verbindet zu

$$\begin{aligned}
 P(\text{Ausfall=ja} / \text{Antragsdaten}) = & \\
 & 1 / [1 + [P(\text{Ausfall=nein}) \\
 * & P(\text{Antragsdaten} / \text{Ausfall=nein})] \quad (\text{Gl. 4}) \\
 & / [P(\text{Ausfall=ja}) \\
 * & P(\text{Antragsdaten} / \text{Ausfall=ja})]].
 \end{aligned}$$

Wenn, wie in den meisten Scorekarten der Fall, die beschreibenden Merkmale nominal skaliert sind (diskrete Wahrscheinlichkeitsverteilung), so ist jeder Kombination eines Antrages eine Wahrscheinlichkeit zuzuordnen. Im Falle eines metrisch skalierten Merkmales müsste die Verteilung durch eine kontinuierliche Wahrscheinlichkeitsverteilung, und damit parametrisch, beschrieben werden. In dieser Version wären die Scorepunkte nicht auf Ausprägungen bezogen, sondern würden sich auf ein ganzes Merkmal anwenden lassen.

Im Falle m unabhängiger Merkmale M_1, M_2, \dots, M_m würde sich für alle möglichen Antragsdaten-Kombinationen die Vertei-

lung $P(\text{Antragsdaten}(M_1, M_2, \dots, M_m)) = P(M_1) * P(M_2) * \dots * P(M_m)$ ergeben. Die Annahme unabhängiger Einzelmerkmale ist, wie aus Untersuchungen in der Praxis bekannt, nicht sehr realistisch – die Korrelationen der Merkmale untereinander sind teils beträchtlich. Daraus ergibt sich die Herausforderung, die Multivariabilität darzustellen. Um Abhängigkeiten zwischen den Merkmalen zu quantifizieren, obwohl die Matrix $P(\text{Antragsdaten} | \text{Ausfall=ja})$ meist spärlich besetzt ist, müsste eine vollständige multivariate Verteilungsannahme getroffen werden. Dies mag nicht trivial erscheinen, es sei an dieser Stelle allerdings darauf hingewiesen, dass bereits die (relativ einfach anmutenden) Expertenkarten gleich schwierig (und damit: ebenso wenig) echt multivariat erstellt werden.

Einbringung qualitativer Faktoren

Ein weiterer Vorteil des Bayesianischen Ansatzes ist die Art und Weise, wie qualitative Informationen über Kreditnehmer in die Schätzung der Ausfallwahrscheinlichkeit eingetragen werden können. Nachdem der Satz von Bayes nicht davon abhängt, wie die zustandsbeschreibenden Parameter der Wahrscheinlichkeitsverteilungen skaliert sind, ist es ohne weiteres möglich, auch „weiche“ Faktoren zu modellieren. Konkret heisst das, man kann die auf den „harten“ Antragsdaten errechnete *a posteriori*-Schätzung $P(\text{Ausfall} | \text{Antragsdaten})$ erweitern um Wissen, das sich in Verteilungen der Art $P(\text{Ausfall} | \text{Qualitatives Urteil})$ abbildet. Eine Zusammenführung der weichen, qualitativen Faktoren aus der Einschätzung des Kreditsachbearbeiters und der harten, quantitativen Faktoren aus der Statistik der Antragsdaten zu einem Ge-

samturteil gelingt aufgrund der Unabhängigkeit der Antragsdatenverteilung von der Verteilung des qualitativen Urteils gemäß der folgenden Formel:

$$P(\text{Ausfall} \mid \text{Antragsdaten}, \text{Qualitatives Urteil}) = P(\text{Ausfall} \mid \text{Antragsdaten}) * P(\text{Ausfall} \mid \text{Qualitatives Urteil})$$

Dynamische Schätzungen

Aus unterschiedlichen Gründen (Eigenkapital-Berechnungen, Portfolio-Analysen, Stress-Tests etc.) ist es wichtig, Scorings des gesamten Bestandes regelmäßig neu zu errechnen. Mit den klassischen Methoden wird hierbei jeder Kreditnehmer durch die Scoring-Gleichung mit seiner Ausfallwahrscheinlichkeit belegt. Mit dem Satz von Bayes ist es nun allerdings vorstellbar, einen Prozess zu installieren, der diese Verteilungen im Sinne einer Updating-Relation dynamisch schätzen kann. Dazu wird eine Bayes-Gleichung für die Verteilung der Ausfallwahrscheinlichkeit des gesamten Portfolios angeschrieben, die sich durch aktuelles Updaten der *a priori* Verteilung ergibt. Als *a priori* kann man dabei die letztmalig erhaltene *a posteriori*-Verteilung einstellen, wodurch sich ein dynamisches Re-Scoring installieren lässt (siehe dazu Rieder, 2004). Ein allfälliges Bestands-Scoring ist dadurch deutlich einfacher zu erhalten als ein mit den klassischen Verfahren geschätztes.

Vergleich der Methodenperformance

Zur Bewertung des hier vorgeschlagenen Verfahrens wird die Bayesianische Methode einer klassischen logistischen Regression gegenübergestellt, da sich die Ergebnisse dieser auch auf der Skala

Ausfallwahrscheinlichkeit messen lassen und die Regression daher dasjenige der oben vorgestellten klassischen Verfahren ist, für das eine direkte Vergleichbarkeit möglich ist.

Die Güte der beiden Ansätze seien entlang von quantitativen und qualitativen Dimensionen gemessen. Zum einen sind das Maße der Trennschärfe, zum anderen Beurteilungen der Interpretierbarkeit und praktischen Handhabbarkeit des jeweiligen Modells.

Beschreibung der Entwicklungsstichprobe

Als reales Beispiel wurden Kreditnehmer-Antragsdaten aus dem Segment der Gewerbekunden und dem Produkt Kontokorrentkredit gewählt. Die Entwicklungsstichprobe setzt sich aus 28.000 guten und 940 schlechten Schuldnern zusammen. Die beim Antrag bekannten Merkmale waren der Schufa-Auskunftei-Index, die Dauer der Kundenbeziehung, die Rechtsform des Unternehmens, die Branche, das Alter des Kreditnehmers und die Postleitzahl des Gewerbestandortes.

Die vorhergesagte Ausfallwahrscheinlichkeit wurde in Klassen gemäß der Standard&Poor's Skala geschnitten. Hiernach bietet sich das folgende Bild der Verteilung Guter und Schlechter über die Ratingklassen:

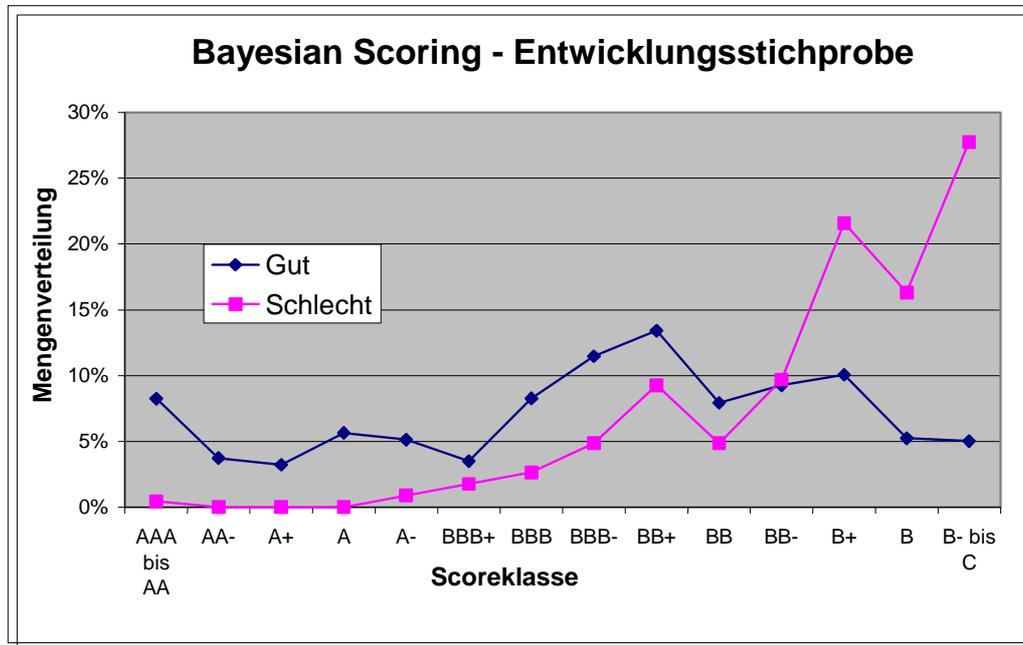


Abbildung 1: Scoreverteilung der Entwicklungsstichprobe (nach Bayesianischem Scoring).

An Abbildung 1 lässt sich eine bei Kreditausfällen häufig auszumachende Beobachtung ablesen. Die Verteilung der guten Fälle ist deutlich flacher als die Verteilung der schlechten Fälle. Mit anderen Worten, die Guten sind deutlich weniger differenzierbar als die Schlechten. Die Schlechten erweisen sich demgegenüber als viel einfacher zu separieren als die Guten. Beim Optimieren der Trennschärfe muss daher beachtet werden, dass der Alpha-Fehler mit steigenden Ratingklassen viel stärker ansteigt als der Beta-Fehler absinkt, welselbiger über die Scoreklassen hinweg relativ gleichmäßig abnimmt.

Bayesianische Scorekarte

Gemäß obigen Überlegungen genügen die Verteilungen guter und schlechter Fälle über die Merkmalsausprägungen, um eine Bayesianische Scorekarte zu erstellen. Wenn man das Verhältnis

$P(\text{Antragsdaten} \mid \text{Ausfall}=\text{nein})$ zu $P(\text{Antragsdaten} \mid \text{Ausfall}=\text{ja})$ als odds ratio bezeichnet, ergibt sich in unserem Fallbeispiel die aus Tabelle 1 ersichtliche Scorekarte (siehe unten).

Zusammen mit der a priori Verteilung kann damit für jeden Kreditnehmer nach Gl. (4) eine Ausfallwahrscheinlichkeit errechnet werden.

Out of sample-Performance

Für die Feststellung der Güte der Scorekarte untersuchen wir Alpha- und Beta-Fehler hinsichtlich des idealen Cutoffs, sowie die Gütemaße Trefferquote und Gini-Koeffizient (Tabelle 2, siehe unten). Diese Maße wurden an einer Validierungsstichprobe (sog. *out of the sample* Probe), also für Kreditnehmer, die nicht Bestandteil der Entwicklungsstichprobe waren, auf einem Portfolio von 9500 Guten und 320 Schlechten errechnet.

	Merkmal				
	Gut	P(Gut)	Schlecht	P(Schlecht)	Odds ratio
Schufa					
1 – 200	724	3,8%	42	18,5%	0,204
201 – 370	2226	11,6%	67	29,5%	0,393
371 – 570	6421	33,4%	77	33,9%	0,986
571 – 650	3383	17,6%	25	11,0%	1,600
651 – 720	3039	15,8%	12	5,3%	2,994
721 – 1000	3410	17,8%	4	1,8%	10,077
Dauer der Kundenbeziehung					
< 25	2307	12,0%	88	38,8%	0,310
25 ≤ x < 40	5599	29,2%	81	35,7%	0,817
40 ≤ x < 55	6115	31,8%	43	18,9%	1,681
≥ 55	5182	27,0%	15	6,6%	4,084
Branche					
Arzt, Notar, Rechtsanwalt	1933	10,1%	4	1,8%	5,713
Dienstleistung	4175	21,7%	16	7,0%	3,085
Land- und Forstwirtschaft	7863	40,9%	92	40,5%	1,010
Metall&Industrie	1724	9,0%	30	13,2%	0,679
Bau	3508	18,3%	85	37,4%	0,488
Rechtsform					
Weiblich	16064	83,7%	184	81,1%	1,032
Unbekannt	946	4,9%	17	7,5%	0,658
Männlich	2193	11,4%	26	11,5%	0,997
Postleitregion					
2, 4, 8	1778	9,3%	12	5,3%	1,751
1, 3, 9	1998	10,4%	17	7,5%	1,389
5, 6	13847	72,1%	168	74,0%	0,974
Rest	1580	8,2%	30	13,2%	0,623

Tabelle 1: Bayesianische Scorekarte

Gütemaß	Logistisch	Bayesianisch
Alpha-Fehler (als Gut klassifizierte Schlechte / Schlechte)	32,3%	24,7%
Beta-Fehler (als Schlecht klassifizierte Gute / Gute)	20,7%	29,5%
Trefferquote (richtig klassifizierte / Alle)	73,2%	72,9%
Gini-Koeffizient	61,3%	60,0%

Tabelle 2: Gütemaße im Vergleich

Die Tabelle zeigt, dass die beiden Verfahren sehr ähnlich performen, auch wenn die logistische Regression im summarischen (das heisst: vom Cutoff unabhängigen) Maß Gini-Koeffizient etwas besser abschneidet. Grund hierfür ist die Tatsache, dass wir für das Bayesianische Scoring im hier vorliegenden *proof-of-concept* keine Korrelation der Merkmale untereinander eingeführt haben. In Testläufen, bei denen dies gemacht wurde, hat sich die Bayesianische Methodik nicht nur als ebenbürtig, sondern als performanter herausgestellt.

Die Performance nach der Trefferquote, welche sich aus Alpha- und Beta-Fehler zusammensetzt, ist vom Cutoff abhängig, und zeigt am idealen Cutoff (dem Cutoff mit der geringsten Summe aus beiden Fehlerarten) innerhalb der statistischen Konfidenzintervallen auf dem Signifikanzniveau von 95 % die gleiche Güte wie das klassische Verfahren.

Die oben angegebenen Performance-Maße für das Bayesianische Scoring sind unter der Maßgabe zu verstehen, dass die *Likelihood* ohne Abhängigkeit der Merkmale untereinander angesetzt wurde. Die errechneten Gütemaße sind daher Untergrenzen, die übertroffen werden, sobald die Korrelationen zwischen den Merkmalen berücksichtigt werden. Die Ergebnisse für die logistische Regression hingegen sind optimiert auf die Trennung guter und schlechter Kreditnehmer, unter Berücksichtigung der vollen Korrelationsmatrix der eingehenden Merkmale. Die Gütemaße der logistischen Regression sind daher die mit diesem Verfahren am höchsten zu erreichenden, was bei den direkten Vergleichen zum Bayesianischen Scoring im Auge zu behalten ist.

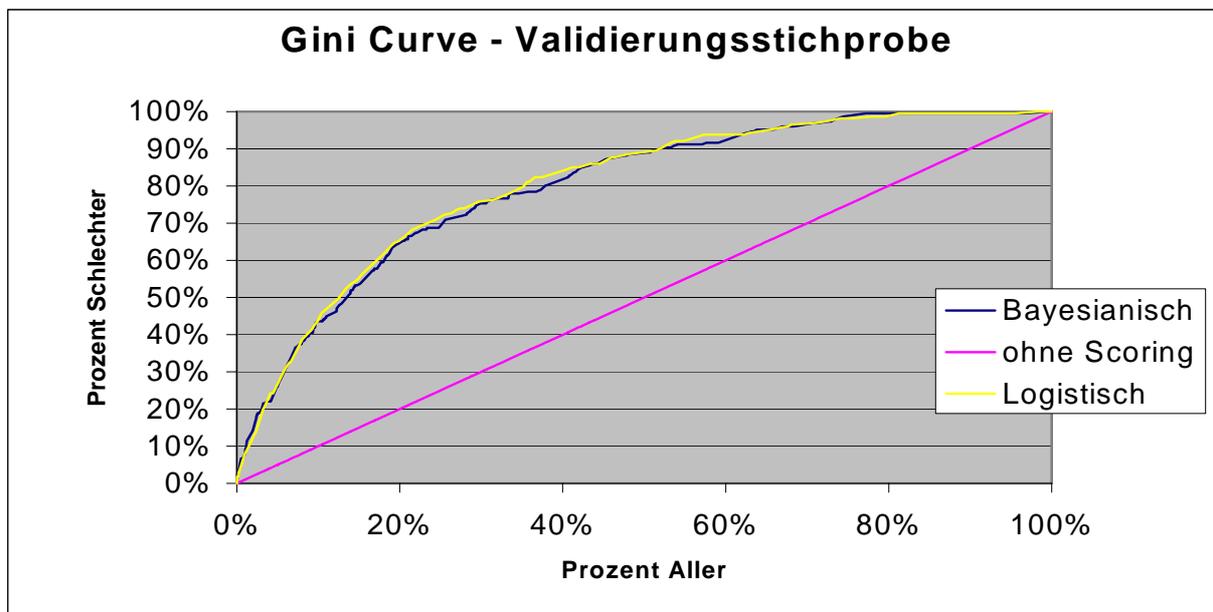


Abbildung 2: Gini-Curve der beiden Scorekarten „Logistisch“ und „Bayesianisch“

Verständlichkeit und Interpretation der Modellgewichte

Die Einführung von Kredit-Scoringssystemen scheitert oftmals daran, dass Vorbehalte gegenüber den angebotenen Lösungen auftreten. So werden zum Teil die Kartengewichte nicht verstanden und Diskussion um deren genaue Bedeutung und fachliches Nachjustieren nach den statistischen Optimierungsläufen sind in der Praxis an der Tagesordnung. Die Bayesianische Methodik liefert als einzige genau das, was Kreditsachbearbeiter ansetzen würden. Sie weiß einerseits um die mittlere zu erwartende Ausfallrate bereits vor Sichtung der Antragsdaten (*a priori*-Wahrscheinlichkeit), und agiert andererseits mit dem Verhältnis von bestimmten Ausprägungen bei guten und schlechten Kreditnehmern.

Die Ergebnisse der vorgestellten Verfahren können allesamt als Scorekarten dargestellt werden. Die Interpretierbarkeit der abgeleiteten Gewichte jedoch ist jedes Mal eine gänzlich andere. Für alle Modelle gilt, dass es zur Risikodifferenzierung ausreicht, auf die relativen Verhältnisse der Gewichte zu achten. Die absoluten Zahlen führen jedoch bei allen drei Methoden zu anderen Interpretationen.

- Expertenkarten geben ihren Gewichten meist gar keine Interpretation mit. Für die Expertenkarten genügt es, auf Differenzen und/oder Relationen zwischen verschiedenen Ausprägungen zu achten. Der summierte Gesamtscore dient lediglich dazu, Kreditnehmer in Klassen zu teilen, hat aber meist per se keine eigene Bedeutung.
- Klassifikationsbäume geben die Schnittpunkte der Merkmale an und

teilen jeder der durch aufeinander folgende Schnitte erhaltenen Gruppen eine Ausfallwahrscheinlichkeit zu. Die logistische Regression und das Bayesianische Scoring geben ebenso Ausfallwahrscheinlichkeiten an. Die Gewichte der Scorekarten nach logistischer Regression sind zunächst nur indirekt über eine Maximum-Likelihood Methode zugänglich und haben dann per se auch nur eine kaum zu kommunizierende, direkte Aussagekraft. Die Interpretationsschwierigkeiten bei den Baumverfahren und der logistischen Regression sind zum einen bedingt durch die Komplexität der statistischen Modelle, zum anderen durch die Unstetigkeit (Bäume) bzw. Nichtlinearität (Regression) der angenommenen Funktionen.

- Die Gewichte der nach Bayesianischem Scoring errechneten Scorekarte hingegen sind sehr einfach zu erhalten und zudem intuitiv eingänglich. Wenn ein Kreditsachbearbeiter z. B. weiß, dass bei guten Kreditnehmern eine bestimmte Altersgruppe doppelt so häufig vorkommt wie eine andere, bei schlechten sich dieses Verhältnis allerdings umkehrt, so ist dieses Wissen direkt in einem Gewicht abgebildet. Das Gewichtsverhältnis sagt somit aus, um wie viel wahrscheinlicher eine bestimmte Ausprägung bei Guten ist als bei Schlechten.

Neben der Herleitung ist auch die Anwendung der Bayesianischen Methodik sehr einfach – die Formel für die Ausfallwahrscheinlichkeit nach Bayes setzt sich aus Divisionen und Additionen zusammen. Nicht nur die technische Implementierbarkeit, auch Akzeptanz und Nachvollziehbarkeit bei den Kreditsachbearbeitern und Risiko-Managern ist der entscheidende Vorteil dieses Verfahrens.

Zusammenfassung und Schlussfolgerungen

Die traditionellen, der klassischen Statistik verpflichteten Methoden für das Kreditantrag-Scoring werden von Kredit-sachbearbeitern regelmäßig in Frage gestellt, weil sie wenig intuitiv, schwer kommunizierbar und nur mäßig nachvollziehbar sind. Ohne eine fundierte Statistik-Ausbildung lassen sich die Gewichte aus der logistischen Regression oder die Schnitte aus Klassifikationsbäumen kaum verstehen und stoßen daher in der Praxis auf Akzeptanzprobleme und Ablehnung.

Die hier vorgeschlagene Methodik entspricht exakt dem Verfahren, das zu einer Scorekarte führen würde, die die Expertenmeinung der Kreditsachbearbeiter widerspiegelt. Dass diese Methodik direkt aus der Bayesianischen Statistik abgeleitet werden kann und somit statistisch fundiert ist, ist ein Argument für deren Weiterentwicklung und Anwendung. Neben der einfachen Interpretation ist es auch die praktikable Handhabbarkeit bei der Berechnung von Ausfallwahrscheinlichkeiten, die simple Methodik zum Einbringen von qualitativen Informationen, die Möglichkeit des einfachen Updatens des Bestands-Scorings und die hohe Trefferquote, die einem Bayesianischen Modell den Vorzug geben lassen.

Kontakt:

Dr. Markus J. Rieder

data2impact Austria
Salurnerstr. 22
A-6330 Kufstein
Tel.: ++43.664.1337035
email: makus.rieder@data2impact.com

Literatur:

Berry, D.A.: "Statistics – A Bayesian Perspective", Duxbury Press, 1996.

Brown, P.J., T. Fearn, and M.S. Haque: "Discrimination with many variables", Journal of the American Statistical Association, Vol. 94, No. 448, 1999.

Gelman, A., J.B. Carlin, H.S. Stern, and D.B. Rubin: "Bayesian Data Analysis", Chapman & Hall, 1995.

Rieder, M.J.: "A Kalman filter approach to dynamic portfolio scoring", in Arbeit, 2004.

Thomas, L.C.: "A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers", International Journal of Forecasting, 16, 149-172, 2000.