

Neue Ansätze in der österreichischen Bankenanalyse

Evelyn Hayden
Jürgen Bauer¹

In dieser Studie werden drei neue Off-Site-Analyseinstrumente vorgestellt, die von der Oesterreichischen Nationalbank (OeNB) und der österreichischen Finanzmarktaufsicht (FMA) mit wissenschaftlicher Unterstützung der Universität Wien entwickelt wurden.² Nachdem Logit-Modelle derzeit in der Fachliteratur wie in der Praxis dem aktuellsten Entwicklungsstand bei der Modellierung von Bonitätseinstufungen entsprechen, wurde in einem ersten Schritt ein Logit-Modell geschätzt, für das ein AUROC-Wert³ von mehr als 80% erreicht werden konnte. In weiterer Folge wurde das Logit-Modell durch ein Cox-Modell ergänzt, um so die Zeitstruktur der Ausfallwahrscheinlichkeiten besser untersuchen zu können. Schließlich wurde zum Nachweis eines eindeutigen Kausalzusammenhangs zwischen den Risiken der Banken und den entsprechenden Ausfallwahrscheinlichkeiten ein strukturelles Modell entwickelt. So wurde für die wichtigsten Risikofaktoren, denen Banken ausgesetzt sind (Kreditrisiko, Marktrisiko und operationales Risiko), ein System aus Value-at-Risk (VaR)-Modellen konstruiert und zum Deckungspotenzial der Banken in Beziehung gesetzt.

Einleitung

Die OeNB und die FMA messen der Entwicklung und Anwendung wirksamer Instrumente zur Off-Site-Analyse große Bedeutung bei. Aus diesem Grund haben die beiden Institutionen kürzlich begonnen, gemeinsam ein neues System von Off-Site-Modellen zu entwickeln, das zusätzlich zu den derzeit verwendeten Analyseinstrumenten implementiert werden soll.⁴ Diese neuen Modelle lassen sich ganz allgemein in statistische und strukturelle Modelle unterteilen. In dieser Studie wird der Begriff „statistisches Modell“ für Systeme verwendet, die sich ausschließlich ökonomischer Methoden bedienen, um aussagekräftige Indikatoren für Bankenrisiken festzulegen, während „strukturelle“ Ansätze Problembanken nicht nur über die Betrachtung von mit Bankenausfällen hoch korrelierten Faktoren identifizieren wollen, sondern darauf abzielen, das Bankenrisiko mithilfe ökonomischer Modelle zu erklären und so eindeutige Kausalzusammenhänge herzustellen.

In der Kategorie der statistischen Modelle hat das Projektteam Logit- und Cox-Modelle entwickelt, die laufend verbessert werden. Im Bereich der strukturellen Modelle wurde im Hinblick auf die wichtigsten Risikofaktoren für Banken (Kreditrisiko, Marktrisiko, operationales Risiko) ein System von Value-at-Risk (VaR)-Modellen konstruiert. Im Folgenden wird ein Überblick über die Modelle geboten, wobei der Schwerpunkt auf den innovativen Aspekten der unterschiedlichen Ansätze liegt.

Statistische Modelle – Das Logit-Modell

Als zentrales statistisches Instrument zur Off-Site-Analyse wählte das Projektteam ein Logit-Modell, da sich die Ergebnisse eines solchen Modells direkt als Ausfallwahrscheinlichkeiten interpretieren lassen. Darüber hinaus gelten Logit-Modelle derzeit sowohl in der Fachliteratur als auch in der Praxis als fortschrittlichstes Instrument zur Modellierung von Bonitätseinstufungen. Bei Logit-Modellen lässt

¹ Evelyn Hayden, OeNB; Jürgen Bauer, FMA. Übersetzung aus dem Englischen.

² OeNB: Evgenia Glogova, Markus Hameter, Andreas Höger, Johannes Turner. FMA: Wolfgang Errath, Stephan Unterberger. Universität Wien: Engelbert Dockner, Michael Halling, Alfred Lehar, Josef Zechner.

³ Die Fläche unter der ROC-Kurve (area under ROC – AUROC) dient als Messgröße für die Prognosegüte von Ratingmodellen. Ein Modell, das perfekt zwischen ausgefallenen und nicht ausgefallenen Schuldnern unterscheidet, erzielt einen AUROC-Wert von 100%. Nähere Einzelheiten finden sich in Sobehart und Keenan (2001) oder Engelmann et al. (2003).

⁴ Siehe Turner (2000).

sich nämlich auf ganz einfache Weise überprüfen, ob die empirische Abhängigkeit zwischen den untersuchten Inputvariablen und dem Ausfallrisiko ökonomisch plausibel ist.⁵

Die größte Herausforderung bei der Entwicklung eines derartigen Modells bestand in der korrekten Definition des Begriffs „Ausfall“. In Österreich existierten in den vergangenen zehn Jahren rund 1.100 Banken, zu denen (in den meisten Fällen seit Dezember 1995) umfassende vierteljährliche Daten⁶ verfügbar sind. In diesem Zeitraum ist in Österreich allerdings kaum eine Bank tatsächlich ausgefallen, so dass die Anzahl der beobachteten Ausfälle viel zu gering ist, um darauf ein statistisches Modell aufzubauen. Darüber hinaus waren sämtliche dieser wenigen Ausfälle auf Ereignisse zurückzuführen, die sich aller Wahrscheinlichkeit nach nicht aus den über die Zeit vor dem Ausfall verfügbaren Daten prognostizieren hätten lassen. Aus diesem Grund sah das Projektteam davon ab, ein Modell für tatsächliche Bankenausfälle zu entwickeln, und definierte stattdessen Ausfall als eine Situation, in der eine Bank in so gravierende Schwierigkeiten gerät, dass eine Lösung der Probleme ohne Intervention (normalerweise in Form von Fusionen mit bzw. Zuschüssen von verbundenen Banken) unwahrscheinlich ist. Ausgehend von dieser Definition erschien es außerdem unrealistisch, die betroffenen Banken erst zum Zeitpunkt der Intervention als Problemfälle zu betrachten; das Projektteam ging daher von der Annahme aus, dass die betreffende Bank bereits mindestens zwei Quartale vor der Intervention in Schwierig-

keiten gewesen sein muss. Ebenso schien die Annahme wahrscheinlich, dass diese Banken mindestens zwei Quartale brauchten, um sich nach einer Intervention vollkommen zu erholen. Daraus lässt sich ableiten, dass die betroffenen Banken fünf aufeinander folgende Quartale hindurch als „ausgefallen“ ausgewiesen werden sollten. Vor diesem Hintergrund konnte ein Datensatz erstellt werden, der über einen Zeitraum von mehr als sieben Jahren rund 33.000 vierteljährliche Beobachtungen und 750 Fälle von Bankenstörungen umfasste.

Nach Ansicht des Projektteams war die Anzahl der beobachteten Ausfälle nun groß genug, um die Daten in ein Schätz- und ein Testsample zu teilen. Um sicherzustellen, dass die Struktur des österreichischen Bankensystems – d. h. wenige große und viele kleine Banken sowie eine Konzentration in bestimmten Bankensektoren – in beiden Datensätzen entsprechend abgebildet war, wurden die 33.000 vierteljährlichen Beobachtungen in sieben Sektorgruppen unterteilt. In jedem dieser Sektoren wurden große und kleine Banken in getrennten Gruppen erfasst. Auf diese Weise entstanden 14 Untergruppen. In einem nächsten Schritt wurden aus jeder der 14 Untergruppen nach dem Zufallsprinzip zwei Drittel der als ausgefallen und der als nicht ausgefallen ausgewiesenen Beobachtungen für das Schätzsample ausgewählt, während die übrigen Beobachtungen aus allen Gruppen das Testsample bildeten.

Auf Grundlage dieses Schätzsamples wurden 280 Kennzahlen als potenzielle erklärende Variablen kons-

⁵ Siehe z. B. Hayden (2003).

⁶ Dazu zählen typische statistische Informationen wie Bilanzdaten, detaillierte Informationen zu Großkrediten (d. h. Kredite über 350.000 EUR) sowie diverse regionale makroökonomische Indizes.

truiert. Diese 280 Kennzahlen lassen sich, wie in unten stehender Tabelle angeführt, in elf Risikokategorien einteilen. Nach der Eliminierung von Ausreißern, der Prüfung der impliziten Linearitätsannahme des Logit-Modells⁷ sowie der Überprüfung, ob die univariaten Zusammenhänge zwischen den potenziellen Inputvariablen und dem Ausfallereignis ökonomisch plausibel⁸ waren, wurden alle Kennzahlen auf ihre univariate Fähigkeit, Problembanken ein Jahr vor dem Eintritt des Ausfallereignisses zu erkennen, getestet. Nur jene Variablen, die eine Accuracy Ratio⁹ von mehr als 5% aufwiesen, kamen für die nähere Analyse in Betracht. Da immer noch mehr als 200 Variablen in diese Gruppe fielen, konnten nicht sämtliche möglichen Modellspezifikationen getestet werden. Es musste also ein anderes Verfahren gefunden werden, mit dessen Hilfe die Auswahl für das endgültige Logit-Modell erfolgen sollte.

Eine mögliche Vorgangsweise hätte darin bestehen können, die jeweils aussagekräftigste univariate Kennzahl jeder der elf Risikokategorien zu ermitteln und diese zum Zweck einer genaueren Untersuchung zu einem multivariaten Modell zu kombinieren. Bei der Untersuchung der Korrelation zwischen den Variablen einer Gruppe fiel jedoch auf, dass nicht alle Kennzahlen hoch korreliert waren, sondern

dass vielmehr einzelne Korrelationsuntergruppen existierten. Daraus lässt sich schließen, dass, wenn nur die Kennzahl mit der höchsten Accuracy Ratio (oder der größten Fläche unter der ROC-Kurve,¹⁰ also dem höchsten AUROC-Wert) aus jeder Risikokategorie in den weiteren Modellierungsprozess eingeflossen wäre, wahrscheinlich das Risiko bestanden hätte, dass wichtige Variablen unberücksichtigt geblieben wären. So wurde stattdessen die beste Kennzahl aus jeder Korrelationsuntergruppe ausgewählt, wodurch die Anzahl der potenziellen Modellvariablen auf 83 sank.

In der Folge wurde diese Gruppe durch die Eliminierung jener Variablen, die eine hohe Korrelation zwischen den einzelnen Risikokategorien aufwiesen, auf 56 reduziert; danach konnte mithilfe so genannter stufenweiser Selektionsverfahren¹¹ überprüft werden, ob sämtliche verbleibende Kennzahlen statistisch signifikant waren oder ob sich das Logit-Modell auf eine kleinere Anzahl von Inputvariablen reduzieren ließ. Tatsächlich besteht das endgültige Modell aus nur zwölf Kennzahlen. Ihre Verteilung auf die Risikokategorien ist in nachstehender Tabelle dargestellt.

Das endgültige Modell wurde auf verschiedene Weise sowohl hinsichtlich seiner Anpassung an die Schätzdaten als auch seiner Prognosegüte im Hinblick auf neue Daten getestet.

⁷ Einige Kennzahlen mussten mithilfe des Hodrick-Prescott-Filters linearisiert werden; siehe Hodrick und Prescott (1997).

⁸ Die Verfahren wurden analog zu den in Hayden (2003) beschriebenen Verfahren gewählt.

⁹ Die Accuracy Ratio ist eine weitere Messgröße für die Prognosegüte von Ratingmodellen, siehe z. B. Keenan und Sobehart (1999). Wie in Engelmann et al. (2003) erläutert, messen die Accuracy Ratio und der AUROC-Wert genau dieselbe Information.

¹⁰ Die ROC-Kurve (Receiver Operating Characteristic – ROC) bildet den Anteil der korrekt prognostizierten Ausfälle in Gegenüberstellung zum Prozentsatz der fälschlicherweise als Ausfälle ausgewiesenen, nicht ausgefallenen Banken für alle möglichen Grenzwerte des getesteten Modells ab. Nähere Einzelheiten finden sich in Sobehart und Keenan (2001) oder Engelmann et al. (2003).

¹¹ Das Signifikanzniveau wurde mit 10% festgelegt.

Tabelle 1

In den statistischen Modellen berücksichtigte Risikofaktoren

	Anzahl der Kennzahlen		
	Ursprünglich	Nach univariater und Korrelationsanalyse	Endgültig
Bankencharakteristika	38	7	1
Kreditrisiko	52	15	3
Kreditrisiko basierend auf Großkrediten	21	5	1
Kapitalstruktur	22	7	2
Rentabilität	41	19	4
Marktrisiko	12	3	–
Liquiditätsrisiko	15	5	–
Operationales Risiko	11	1	–
Reputationsrisiko	6	2	–
Managementqualität	13	5	–
Makroökonomische Faktoren	49	14	1
Gesamt	280	83	12

Zur Überprüfung der Anpassung des Modells wurden die typischen statistischen Tests für Logit-Modelle – z. B. Deviance-, Leverage- oder der Goodness-of-Fit-Test nach Hosmer-Lemeshow – eingesetzt. Das weithin anerkannte Konzept der Accuracy Ratio bzw. des AUROC-Werts diente hauptsächlich zur Bewertung der Prognosegüte des Modells; es kamen jedoch auch die neuesten Verfahren zur Berechnung von Konfidenzintervallen für die oben genannten Messgrößen zur Anwendung. Außerdem wurden strikte statistische Tests durchgeführt, um die Überlegenheit des finalen Logit-Modells gegenüber anderen Ratingmethoden sicherzustellen.¹² Weiters generierte das Projektteam zusätzlich zu den Ergebnissen des einen Testsamples nach dem Zufallsprinzip noch weitere Stichpro-

ben aus dem gesamten Datenpool, um die Performance des Logit-Modells auch für diese Testsamples zu evaluieren. Dabei erwiesen sich sowohl die Anpassung als auch die Prognosegüte des Modells als zufrieden stellend und über mehrere Datensamples hinweg als äußerst stabil. Zur näheren Illustration ist in unten stehender Tabelle der AUROC-Wert für das Schätz- und das ursprüngliche Testsample angeführt.

Abschließend wurden die geschätzten Modellwahrscheinlichkeiten kalibriert, um Wahrscheinlichkeiten für „gravierende Probleme“ bei Banken und „tatsächlichen Ausfall“ zu erhalten. Darüber hinaus wurden diese Werte in ein Ratingsystem übertragen, um die Schwankungen bei den Ergebnissen für einzelne Banken in der Zeitreihe zu reduzieren.

Tabelle 2

Prognosegüte des Modells gemessen am AUROC-Wert

	AUROC in %	σ_{AUROC}	Konfidenzintervall von 95%
Sample	82,87	0,0129	[0,8034, 0,8539]
Out-of-sample	80,63	0,0210	[0,7651, 0,8475]

¹² Siehe Engelmann et al. (2003).

Statistische Modelle – Das Cox-Modell

Die OeNB und die FMA beschlossen, unter Verwendung derselben Datenbasis und derselben möglichen Inputvariablen zusätzlich zum Logit-Modell ein Cox-Proportional-Hazard-Rate-Modell zu entwickeln. Ursprünglich war diese Entscheidung sowohl durch das Bestreben begründet, mehr über die Zeitstruktur der Wahrscheinlichkeiten von Bankenausfällen oder -problemen (d. h. über die Überlebensfunktion einer durchschnittlichen „ausfallenden“ Bank) zu erfahren, als auch durch die Idee, die Ergebnisse des Logit-Modells anhand der Resultate des Cox-Modells auf ihre Stichhaltigkeit zu überprüfen. Später jedoch gelang es dem Projektteam, im Rahmen einer innovativen Lösung das Cox-Modell als komplementäre Ergänzung zum Logit-Modell zu konstruieren.

Wenn Cox-Proportional-Hazard-Rate-Modelle in der Fachliteratur¹³ dazu eingesetzt werden, um Bankenausfälle vorherzusagen, sind sie normalerweise so konstruiert, dass die Beobachtungszeiträume für alle Banken zum selben Zeitpunkt beginnen.¹⁴ Im Fall des österreichischen Datensatzes, für den Informationen über Banken seit Dezember 1995 herangezogen wurden, würde dies implizieren, dass die Beobachtungszeiträume für alle österreichischen Banken zu genau diesem Zeitpunkt (Dezember 1995) beginnen sollten. In diesem Szenario würde mithilfe des Cox-Modells und auf Basis der zur Verfügung stehenden Inputdaten der Versuch unternommen, diejenigen

Banken, die in einem frühen Stadium mit Problemen konfrontiert sind, von denjenigen zu trennen, bei denen dies in einem späteren Stadium (oder gar nicht) der Fall ist. Somit würde das Modell anzeigen, ob eine Bank ausfallgefährdet ist oder nicht.

Ein Alternativverfahren bestünde darin, einen bestimmten Grenzwert für den aus dem Logit-Modell erzielten Output festzulegen und die österreichischen Banken entsprechend als „ausgefallen“ oder „nicht ausgefallen“ einzustufen (bzw. als gefährdete/nicht gefährdete Banken).¹⁵ In diesem Fall sollten nur diejenigen Banken, die gemäß dem oben beschriebenen Verfahren als gefährdet ausgewiesen sind, in das Cox-Modell einbezogen werden, wobei der Beobachtungszeitraum dann beginnt, wenn die Bank den festgelegten Grenzwert erstmals überschreitet. Nachdem das Logit-Modell einige Banken fehlklassifiziert (wie dies bei einem statistischen Modell per definitionem der Fall ist), würde das Cox-Modell einige nicht ausgefallene Banken mitberücksichtigen. Das bedeutet, dass in diesem Szenario jene Parameter in das Cox-Modell einbezogen würden, die die präziseste Prognose darüber ermöglichen, ob ausfallgefährdete Banken zu einem späteren Zeitpunkt tatsächlich ausfallen. Nachdem also sämtliche im Logit-Modell als gefährdet ausgewiesene Banken durch das Cox-Modell neu klassifiziert werden, weist der gemeinsame Output der beiden Modelle wahrscheinlich eine höhere Accuracy Ratio¹⁶ auf als das Logit-Modell allein.

¹³ Siehe z. B. Henebry (1996).

¹⁴ Dasselbe gilt für die Vorhersage von Leistungsstörungen nichtfinanzieller Unternehmen.

¹⁵ In diesem Fall sollte der Grenzwert auf ein Niveau gesetzt werden, bei dem (beinahe) alle Problembanken korrekt klassifiziert werden können.

¹⁶ Der Output des Cox Proportional Hazard Rate-Modells besteht aus relativen Hazard-Raten für die beobachteten Banken. Wie die Ausfallwahrscheinlichkeiten des Logit-Modells können auch Hazard-Raten dazu dienen, Banken nach dem wahrgenommenen Risiko zu reihen; somit können sie auch als Grundlage zur Berechnung der Accuracy Ratio herangezogen werden.

Bei der Entwicklung der beiden Versionen des Cox-Modells kamen ähnliche Verfahren zur Anwendung, wie sie bereits für das Logit-Modell beschrieben wurden. Während die klassische Version des Cox-Proportional-Hazard-Rate-Modells bereits einsetzbar ist, ist der Entwicklungsprozess für das fortgeschrittene Cox-Modell noch nicht abgeschlossen.

Strukturelle Modelle

Zusätzlich zu den oben beschriebenen statistischen Modellen beschlossen die OeNB und die FMA, ein strukturelles Modell zu entwickeln, das klare kausale Zusammenhänge zwischen den Risiken und der Ausfallwahrscheinlichkeit von Banken modellieren sollte. So wurde für die wichtigsten Risikofaktoren, denen Banken ausgesetzt sind – Kreditrisiko, Marktrisiko und operationales Risiko – ein System aus Value-at-Risk (VaR)-Modellen konstruiert und zum Deckungspotenzial der Banken in Bezug gesetzt. Im Anschluss findet sich eine Zusammenfassung der einzelnen Komponenten dieses Modells.

Kredit-VaR-Modell

Im Zuge der Entwicklung eines Kredit-VaR-Modells überprüfte das Projektteam zunächst die drei gängigsten Kreditrisikomodelle (KMV, CreditMetrics und CreditRisk+¹⁷) und wählte schließlich CreditRisk+. Diese Wahl war in erster Linie auf das eingeschränkte Angebot von Eingabedaten zurückzuführen. Die für das KMV-Modell erforderlichen Marktdaten liegen nämlich nur für die beiden größten österreichischen Banken vor, und Ratingdaten für sämtliche Einzelkredite – ein wesentlicher Input für CreditMetrics – stehen der österrei-

chischen Bankenaufsicht noch nicht in der gewünschten Qualität zur Verfügung. Die OeNB erhebt jedoch bereits seit einigen Jahren Daten zu Großkrediten, die als wichtigste Grundlage für den folgenden Ansatz dienen konnten.

Das Projektteam entschied sich für die Implementierung eines CreditRisk+-Modells, mit dem die verfügbaren Informationen über die Verteilung der von den Banken vergebenen Kredite über verschiedene Branchen verwendet werden konnten. Während das Projektteam den CreditRisk+-Ansatz unter der Annahme fixer Ausfallfrequenzen pro Branche einerseits als zu unrealistisch einstufte, schien andererseits die Implementierung eines CreditRisk+-Modells auf Grundlage vieler einzelner Branchen mit stochastischen Ausfallraten für eine erste Modellversion zu aufwendig zu sein. Daher kam das im Folgenden dargestellte gemischte Verfahren zur Anwendung.

Sämtliche Großkredite wurden elf breit definierten Branchen zugeordnet, in denen die jeweiligen Kreditnehmer tätig waren. Da für diese Branchen zudem historische Ausfalldaten vorlagen, konnte das Projektteam die einzelnen empirischen Ausfallhäufigkeiten und Standardabweichungen für alle elf Branchen errechnen. Der Verlust bei Ausfall (loss given default – LGD) musste jedoch für alle Branchen mit einem fixen Prozentsatz approximiert werden. Als Nächstes wurden alle Großkredite für jede einzelne Bank verschiedenen LGD-Bändern zugeordnet. Durch die Interpretation der historischen Ausfallraten pro Branche als erwartete künftige Ausfallwahrscheinlichkeiten und durch die Berücksichtigung der

¹⁷ Siehe Crouhy et al. (2000).

Branchenzusammensetzung der Kredite pro Band konnte das Projektteam die erwartete Anzahl von Ausfällen (und Standardabweichungen) pro Band ableiten. Nachdem seit dem Jahr 2003 mit der monatlichen Großkreditmeldung auch die entsprechenden Ratinginformationen verfügbar sind, beschloss das Projektteam, die Wahrscheinlichkeiten, die aus dem zu den einzelnen Branchen vorliegenden Datenmaterial resultieren, anhand dieser Ratinginformationen anzupassen. Die angepassten Zahlen wurden über sämtliche Bänder addiert; auf diese Weise konnte die erwartete Anzahl an Ausfällen einer „Meta“-Branche ermittelt werden. Durch dieses Verfahren wurden sämtliche Informationen gewonnen, die nötig sind, um ein CreditRisk+-Modell mit einem einzigen stochastischen Prozess zu berechnen.

Da jedoch kleine Banken normalerweise nur selten Großkredite gewähren, wurde das oben beschriebene Verfahren dahin gehend verbessert, dass das Volumen der Kleinkredite näherungsweise aus den Rohbilanzdaten im Monatsausweis ermittelt und im Modell berücksichtigt wurde. Hierfür wurde das approximierten Gesamtvolumen der Kleinkredite pro Bank dem geringsten LGD-Band zugewiesen. Zuletzt konnte unter der Annahme, dass sämtliche Kleinkredite etwa dasselbe Volumen haben, die Anzahl der Kleinkredite pro Bank durch Division des Volumens der Kleinkredite durch die Bandbreite des jeweiligen LGD-Bandes annähernd ermittelt werden. Alle weiteren Schritte dieses Ansatzes wurden analog zum oben beschriebenen Verfahren ausgeführt.

Markt-VaR-Modell

Das österreichische Markt-VaR-Modell konzentriert sich auf das Zinspositionsrisiko, das Aktienrisiko und das Wechselkursrisiko. Es wurde als Standard-Delta-Normal-Ansatz auf Basis täglicher Varianz-Kovarianz-Matrizen für die Risikofaktoren implementiert. Die größte Herausforderung dabei bestand darin, die notwendigen Inputdaten für Testberechnungen zu erheben, da die Daten, die die Banken derzeit melden müssen (insbesondere im Hinblick auf das Aktienrisiko bei Banken mit starken Handelsaktivitäten) nicht ausreichend genau waren.

Operationales VaR-Modell

Die österreichischen Banken erheben zwar bereits die für die korrekte Quantifizierung dieses Risikos erforderlichen Daten zu operationalen Verlusten, diese Daten stehen der Aufsichtsbehörde aber noch nicht zur Verfügung. Das Projektteam stimmt allerdings internationalen Studien zu, denen zufolge das operationale Risiko einen bedeutenden Risikofaktor darstellt; laut den entsprechenden Berechnungen dient das von den Banken gehaltene ökonomische Eigenkapital zu bis zu 30% der Abdeckung des operationalen Risikos. Ausgehend von dieser Annahme wurde auf Basis des Basisindikatoransatzes (Basel II) folgender provisorischer Ansatz entwickelt, um zumindest eine grobe Annäherung dieses Risikofaktors in die erste Version des Strukturmodells einbeziehen zu können.

Nimmt man an, dass die Frequenz operationaler Verlustereignisse geometrisch verteilt ist und approximiert man den Verlust pro Ereignis über eine Exponentialverteilung, dann ist der auf operationales Risiko zurückzuführende Gesamtverlust ebenfalls

exponentiell verteilt und kann daher vollständig über die Identifizierung eines einzelnen Parameters beschrieben werden. Daraus folgt, dass der operationale VaR für jedes Konfidenzniveau berechnet werden kann, sobald dieser eine Parameter bekannt ist. Seine Berechnung basiert auf der Tatsache, dass fortgeschrittene Messansätze nach Basel II zur Berechnung der Mindesteigenkapitalunterlegung ein Konfidenzniveau von 99,9% erfordern, sowie auf der Annahme, dass auch der einfach zu implementierende Basisindikatoransatz auf dieses Konfidenzniveau kalibriert wurde.

Aggregation der VaRs

Sind die einzelnen VaRs einmal berechnet, müssen sie aggregiert werden, um einen Gesamt-VaR pro Bank zu erhalten. Dieser Schritt stellte das Projektteam vor die wahrscheinlich größte Herausforderung.

Zunächst mussten die einzelnen VaRs so angepasst werden, dass sie Risikokennzahlen für gleiche Zeitabschnitte darstellten, da der Kredit-VaR und der operationale VaR auf Jahresbasis ermittelt wurden, der Markt-VaR hingegen auf Tagesbasis. Da die Ratingagenturen normalerweise jährliche Ausfallwahrscheinlichkeiten angeben und auch in Basel II dieser Zeithorizont bevorzugt wird, wurde der Markt-VaR entsprechend angepasst. Dabei wurde der Markt-VaR auf Tagesbasis mit der Quadratwurzel von 250 hochskaliert. Laut Ansicht des Projektteams stellt dies das beste und konsistenteste Verfahren dar, obwohl einzuräumen ist, dass dabei wahrscheinlich das Marktrisiko überschätzt wird, da es für die Banken sehr einfach ist, ihr Handelsportfolio über einen viel kürzeren Zeitraum hinweg umzustrukturieren.

Hinsichtlich der eigentlichen Aggregation der einzelnen VaR-Komponenten wurden hauptsächlich zwei Ansätze evaluiert – die Aggregation über die Varianz-Kovarianz-Matrix und die Anwendung von Kopulas. Beide Methoden konnten jedoch nicht überzeugen. Einerseits ist die Verwendung einer Varianz-Kovarianz-Matrix nur theoretisch fundiert, wenn die Risikofaktoren normal verteilt sind, was insbesondere für das Kreditrisiko und das operationale Risiko fragwürdig erscheint; außerdem scheint unklar, wie die Schätzung der Kovarianzen erfolgen soll, insbesondere, wenn man berücksichtigt, dass die Zusammensetzung von Marktportfolios sehr volatil sein kann. Andererseits ist die Verwendung von Kopulas relativ aufwendig und es bleibt offen, ob dieser Präzisionsgrad für die Aggregation überhaupt notwendig ist, wenn man die Approximationen berücksichtigt, die zur Berechnung der individuellen VaRs erforderlich sind. Aufgrund dieser Überlegungen und der Ansicht, dass im Zweifelsfall eine Überschätzung der Ausfallwahrscheinlichkeiten einer Bank einer Unterschätzung vorzuziehen sei, entschied sich das Projektteam für einen konservativen Ansatz, bei dem der Gesamt-VaR als die einfache Summe der einzelnen VaRs definiert wurde.

Das Deckungspotenzial der Banken

Der letzte Schritt im Rahmen des Strukturmodells besteht darin, den Gesamt-VaR der Banken mit deren Fähigkeit, Verluste abzudecken, in Verbindung zu setzen. Anhand der gesamten VaR-Verteilung lässt sich das Signifikanzniveau berechnen, zu dem die zur Verlustabdeckung verfügbaren Mittel einer Bank genau dem VaR entsprechen. Die Ausfallwahr-

scheinlichkeit für die Bank beträgt dann genau 1 minus diesen Wert.

Im Rahmen des Strukturmodells wurde bereits eine Reihe von Testberechnungen für einen Kreis ausgewählter Banken – einschließlich großer Banken, die für den gesamten Bankensektor hoch relevant sind, sowie kleinerer Sektorbanken – durchgeführt. In allen Fällen weisen die Ergebnisse eine plausible Größenordnung auf und bestätigen somit die gewählten Modellspezifikationen.

Insgesamt ist das Projektteam der Überzeugung, dass – obwohl das Strukturmodell derzeit auf einer Reihe vereinfachender Annahmen basiert – der Grundstein für ein umfassendes Modell gelegt worden ist, mit dessen Hilfe die Risiken, mit denen Banken konfrontiert sind, durch sehr klare Kausalzusammenhänge erklärt und vorhergesagt werden können. Die modulare Struktur dieses Ansatzes erleichtert weitere Verbesserungen des Modells, da die spezifischen Komponenten sofort

aktualisiert werden können, wenn neue Daten oder Erkenntnisse vorliegen, ohne dass dabei das gesamte System angepasst werden muss.

Zusammenfassung und Ausblick

Die OeNB und die FMA haben im Rahmen einer intensiven Zusammenarbeit eine Reihe moderner, aussagekräftiger Instrumente für die Off-Site-Analyse entwickelt. Obwohl die Prognosefähigkeit dieser neuen Modelle bereits jetzt sehr zufrieden stellend ist, werden die Arbeiten fortgesetzt, um die Ergebnisse weiter zu verbessern und sicherzustellen, dass die statistischen Instrumente dem jeweils neuesten Stand der Wissenschaft, aber auch der Praxis entsprechen. Nähere Einzelheiten zu den hier vorgestellten Modellen werden im Herbst 2004 veröffentlicht; das überarbeitete österreichische Bankenanalysesystem, in das die hier diskutierten Modelle einfließen werden, soll im Frühjahr 2005 präsentiert werden.

Literaturverzeichnis

- Crouhy, M., D. Galai und R. Mark. 2000.** A Comparative Analysis of Current Credit Risk Models. In: *Journal of Banking and Finance* 24. 59–117.
- Engelmann, B., E. Hayden und D. Tasche. 2003.** Testing Rating Accuracy. In: *Risk* 16. 82–86.
- Hayden, E. 2003.** Are Credit Scoring Models Sensitive to Different Default Definitions? Evidence from the Austrian Market. SSRN Working Paper.
- Henebry, K. 1996.** Do Cash Flow Variables Improve the Predictive Accuracy of a Cox Proportional Hazards Model for Bank Failure? In: *The Quarterly Review of Economics and Finance* 36. 395–409.
- Hodrick, R. und C. Prescott. 1997.** Post-War U.S. Business Cycles: An Empirical Investigation. In: *Journal of Money, Credit and Banking* 29. 1–16.
- Keenan, S. und J. Sobehart. 1999.** Performance Measures for Credit Risk Models. Moody's Risk Management Services.
- Sobehart, J. und S. Keenan. 2001.** Measuring Default Accurately. In: *Credit Risk Special Report*, Risk 14. March. 31–33.
- Turner, J. 2000.** Das österreichische Bankenanalysesystem. In: *Berichte und Studien* 1. OeNB, 90–100.