

Preparativos para o Novo Acordo da Basiléia

Parte 4: Tempo que Precede a Inadimplência

Previous articles in this series have focused on the problems of missing data, model building strategies, and special

challenges in model validation — topics often associated with modeling retail portfolios. This article moves a bit beyond Basel, offering additional tools to further enhance risk and account management strategies. Building a quantitatively based framework — beyond any Basel II requirements — is just plain old good risk management.

Banks opting for advanced status under Basel II are expected to have, among other things, models for PD (probability of default) and LGD (loss given default). Some of these models will be provided by outside vendors, while others will be more custom driven. Previous articles in The RMA Journal have discussed how to build both PD and LGD models¹. A PD model will let you know the probability of a loan defaulting sometime in the next year. Looking at the modeling results, you might think that lo-

Jeffrey S. Morrison

Preparing for Basel II

Part 4: Time to Default

Artigos anteriores desta série concentraram-se nos problemas dos dados ausentes, das estratégias de construção de modelos e de desafios específicos da validação de modelos — tópicos freqüentemente associados à modelagem de carteiras de varejo. Este artigo vai um pouco além da Basiléia, oferecendo ferramentas adicionais para aprimorar ainda mais as estratégias de gerenciamento de risco e de contas. Construir um arcabouço de bases quantitativas — além de atender a quaisquer requisitos do Novo Acordo da Basiléia — significa boa gestão do risco.

Os bancos que optam pela situação avançada nos termos do Novo Acordo da Basiléia devem ter, entre outras coisas, modelos de PI (probabilidade de inadimplência) e de PCI (perda em caso de inadimplência). Alguns desses modelos procedem de fornecedores externos, enquanto outros são mais personalizados. Em artigos anteriores, já foi discutido como construir modelos de PI e PCI¹. Um modelo de PI permite saber a probabilidade de um tomador de empréstimo vir a se tornar inadimplente em algum momento do

ano seguinte. Analisando os resultados da modelagem, poderíamos imaginar que empréstimos com PI estimada em 0,95 ficarão inadimplentes mais rapidamente do que outros com PI de 0,45 ou menos. O modelo de PI, contudo, não foi concebido para lidar com essa questão. Esses modelos não procuram descrever o momento exato da inadimplência — seja dentro de um ano ou em tempo mais amplo. Não seria bom saber — no momento da contratação ou em algum outro ponto da vida do empréstimo — quando poderia ocorrer a inadimplência? É evidente que se houvesse expectativa de que o empréstimo entraria em inadimplência em poucos meses, contratá-lo não valeria a pena.

Mas, e caso se saiba que a probabilidade de inadimplência de um empréstimo específico será baixa nos três primeiros anos podendo aumentar drasticamente depois desse período? Valeria a pena? Sob que condições o banco poderia contratar esse empréstimo?

A modelagem do tempo que precede a inadimplência não exige nada além de uma pequena variação de uma técnica estatística, já discutida em artigos anteriores. Embora a construção de um bom modelo de tempo que antecede a inadimplência possa ser um desafio, o sucesso com os modelos de PI e PCI, associado a uma base de dados abrangente e bem compreendida, deverá ser um bom ponto de partida. Se for bem-sucedida, uma organização poderá dispor de um mecanismo que ajudará a prever a que tempo uma conta entrará em inadimplência — uma previsão realizada com antecipação suficiente para impedir que a perda ocorra ou para atenuar seu impacto caso ela se concretize ou, no mínimo, oferecer *insight*

ans with an estimated PD of .95 will default more quickly than ones with a PD of .45 or lower. The PD model, however, was never designed to address this issue. Such model makes no attempt at describing the exact timing of default — either within the year or further down the road. Wouldn't it be nice to know — at booking or at any time during the life of the loan — when the default might occur? Obviously, if the loan were expected to default in the next few months it would not be worth your while to book it. But what if you knew that the probability of default for a particular loan might stay low for the first three years but increase dramatically thereafter? Would it be worthwhile then to know? Under what conditions might you book it?

Modeling time to default requires nothing but a slight variation to a statistical technique already discussed in previous articles. Although building a good time-to-default model can prove challenging, your success with PD and LGD models, coupled with a comprehensive and well-understood database, should give you a great head start. If successful, your organization will have a mechanism to help predict when an account will default — a prediction made early enough that it might prevent the loss from occurring, mitigate its impact if it does occur, or at the very least provide insight into the profitability, pricing, or term structure of the loan. For illustration purposes and to keep things simple, we will use a hypothetical dataset with generically labeled variables called X1, X2, and X3. In reality, the-

se might be predictors such as LTV, debt to income, fixed-versus-variable interest rate, term of loan, and so forth.

Let's start with a story. Three economists went deer hunting. The first economist saw a deer and shot to the left of the animal, missing it by about two feet. The second economist shot it to the right of the deer, missing it by about the same margin. Immediately afterwards and with unbridled enthusiasm, the third economist stood up and shouted, "We got him, we got him!!" The idea here is that economists who focus on predicting when an event will occur (such as a downturn in the economy) realize the difficulty of their task. They are happy simply when they come close. Whereas previous articles in this series looked at methods of predicting if an account will default sometime within a 12-month window of time, we now consider a more formidable task – the timing of default.

Censored Data and Survival Analysis

The task is more formidable for two reasons. First, obtaining a certain level of ac-

quanto à lucratividade, precificação ou estrutura de prazos do empréstimo. Para exemplificar e simplificar, usaremos um conjunto de dados hipotético, com variáveis genéricas chamadas X1, X2 e X3. Na realidade, elas poderiam ser variáveis preditivas como índice empréstimo/valor, dívida/renda, taxa de juros fixa ou variável, prazo do empréstimo e assim por diante.

Podemos começar com uma anedota. Três economistas estavam caçando cervos. O primeiro viu um cervo e atirou à esquerda da presa, errando por cerca de 60 centímetros. O segundo economista atirou à direita do cervo, errando pela mesma margem aproximada. Logo em seguida, e com entusiasmo incontido, o terceiro economista levantou-se e exclamou: "Acertamos!! Acertamos!!" A moral da estória é que os economistas que se concentram em prever quando um evento se dará (como uma queda da atividade econômica) sabem o quanto a tarefa é difícil. Basta chegar perto para se sentirem felizes. Enquanto artigos anteriores desta

série trataram de métodos para prever se uma conta entrará em inadimplência no prazo de um ano, neste será abordada uma tarefa mais formidável – o momento da inadimplência.

Dados Censurados e Análise de Sobrevivência

A tarefa é especialmente formidável por dois motivos. Primeiro, obter um determinado nível

*High hazard
rate has its
survival time
small.*

*Taxa de risco
elevada implica
tempo de
sobrevivência
breve.*

de precisão ao longo do tempo é inerentemente mais difícil do que em métodos mais simples de classificação. Em outras palavras, é muito mais difícil explicar diversos tons de cinza do que explicar que um objeto é preto ou branco. Assim, pode ser necessário dispor de um padrão melhor de dados preditivos. O segundo motivo tem a ver com censura de dados — uma situação em que informações importantes ou não estão disponíveis ou só existem fora do período de estudo. Como o esforço de coleta de dados para qualquer estudo abrange um período específico, haverá muitas contas cuja situação final se desconhece. Na verdade, essas contas serão a maioria dos dados. Esse detalhe, aparentemente pequeno, afeta não apenas a precisão do modelo preditivo como também a escolha da ferramenta estatística.

Prever o tempo até a inadimplência é parte de um campo de estudos mais amplo denominado de análise de sobrevivência. Grande parte dos avanços nesse campo é devida a pesquisas militares da Segunda Guerra Mundial cujo objetivo era prever o tempo que decorreria até que um equipamento militar apresentasse falhas. Combinada aos recentes avanços da informática e ao teste acelerado de novas drogas em testes clínicos, a análise de sobrevivência ressurgiu de maneira drástica. Como muitos outros campos de estudos, a análise de sobrevivência tem seu próprio jargão. Um termo usado é *hazard rate* (taxa de risco). No que tange ao risco de crédito, a taxa de risco é a probabilidade de que uma conta se torne inadimplente em algum tempo dividida pela probabilidade de que a conta tenha sobrevivido até aquele instante. Se uma conta tiver taxa de risco elevada, seu tempo de sobrevivência será

accuracy across time is inherently far more difficult than in simpler classification methods. In other words, it's much harder to explain various degrees of gray than to explain an object being either black or white. Therefore, a higher standard of predictive data may be required. The second reason deals with censoring — a data issue where important information is not available or is present only outside the study period. Given that the data collection efforts for any study cover a specific period, there will be many accounts whose final default status you will not know. In fact, those accounts will make up the majority of your data. This seemingly small detail dramatically affects not only the accuracy of the predictive model, but also the choice of the statistical tool.

Predicting time to default is part of a larger field of study called survival analysis. Much of the progress in this field came from World War II military research, where the aim was to predict time to failure of military equipment. Combined with recent advances in computer technology and the rapid testing of new drugs in clinical trials, survival analysis has experienced a dramatic resurgence. Like many other fields of study, survival analysis has its own terminology. One term is hazard rate. With respect to credit risk, the hazard rate is the chance that an account will default in some increment of time, divided by the chance that the account has "survived" up to that point. If an account has a high hazard rate, then its survival time is small. If it has a low hazard

rate, then its survival time is large. These hazard rates can have different shapes over time. The good news is that they can be accounted for in the modeling process.

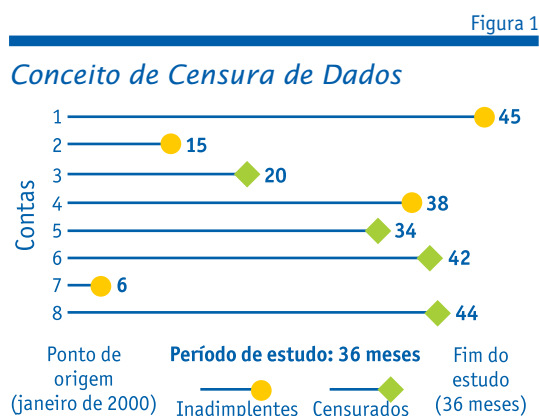
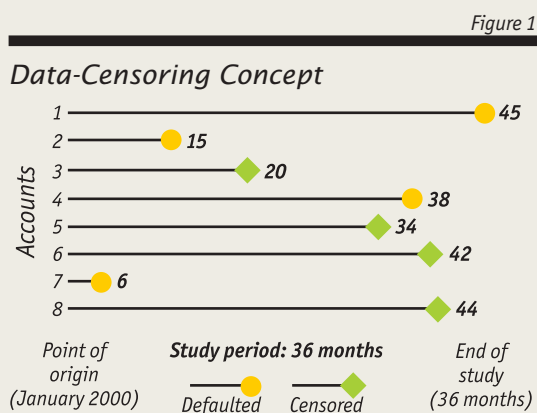
Perhaps the easiest way to understand time-to-default modeling is to look at some data. Figure 1 shows eight hypothetical retail loans selected at random. Assume for each account we have three variables to predict time to default – X_1 , X_2 , and X_3 . Further assume that this information does not change over time. The starting point of the study is the point of origin – that snapshot in time where we begin tracking account status and performance. In our example, let's use January 2000 as the point of origin. If we measure time in months since the point of origin, then a survival time of 12 means that our account experienced payment default 12 months after January 2000, or January 2001.

Figure 1 shows the tracking of accounts over a 36-month window. If the point of origin is January 2000, then the end of the study period is January 2004. Past this period we would not know whether an account

breve. Se a taxa de risco for baixa, o tempo de sobrevivência será maior. As taxas de risco podem apresentar diferentes perfis ao longo do tempo. Mas a boa nova é que elas podem ser levadas em consideração no processo de modelagem.

Talvez a melhor maneira de entender a modelagem do tempo que precede a inadimplência seja estudando alguns dados. A Figura 1 mostra outros empréstimos de varejo hipotéticos, escolhidos aleatoriamente. Admitamos que, para cada conta, tenhamos três variáveis para previsão do tempo precedente à inadimplência – X_1 , X_2 e X_3 . Consideremos, ainda, que essas informações não mudem com o passar do tempo. O ponto de partida do estudo é o ponto de origem – o instante em que começamos a monitorar a situação e o desempenho das contas. Em nosso exemplo, vamos usar, como ponto de origem, janeiro de 2000. Se medirmos o tempo em meses desde o ponto de origem, um tempo de sobrevivência de um ano significará que nossa conta tornou-se inadimplente 12 meses depois de janeiro de 2000, ou seja, em janeiro de 2001.

A Figura 1 mostra o monitoramento das contas num período de 36 meses. Se o ponto de origem é janeiro de 2000, o fim do período estudado será



janeiro de 2004. Depois desse ponto, não poderemos saber se uma conta tornou-se inadimplente. E, se não soubermos, essas contas representarão dados censurados. A censura também pode ocorrer antes do fim do período de estudo. A Conta 3 pode ter sido encerrada por causa de um falecimento. A Conta 5 pode ter sido fechada a pedido do cliente por motivos normais de atrito. Nesse quadro, se uma conta não se tornou inadimplente, seu valor é considerado censurado. Assim, no exemplo da Figura 1, todos os empréstimos são considerados censurados, com exceção das Contas 2 e 7, ambas inadimplentes.

Tendo em mente a Figura 1, vamos transformar essas oito contas em dados adequados para a modelagem. A Figura 2 mostra a criação da variável dependente (tempo de sobrevivência) para nosso modelo de tempo até a inadimplência. Como já vimos, a variável dependente é o que desejamos prever. Mas, na modelagem de sobrevivência, precisamos de uma variável para identificar a censura. Aqui, a denominamos censor. Observe-se que não há períodos de sobrevivência superiores a 36 meses, porque esse é o fim de nosso período de estudo — o limite de censura. Censor é uma variável 0 / 1 que indica se a observação representa ou não uma conta censurada. As variáveis censuradas recebem valor 0. As demais recebem valor 1.

has defaulted. If we do not know, then those accounts represent censored data. Censoring also can occur before the end of the study period. Account 3 could have been closed due to a death event. Account 5 could have been closed at the request of the customer for normal attrition reasons. In this framework, if an account has not defaulted, then its value is considered censored. Therefore, in our Figure 1 example, all loans are considered censored except for accounts 2 and 7, both of which defaulted.

With Figure 1 in mind, let's turn these eight accounts into data appropriate for modeling. Figure 2 shows the creation of the dependent variable (survival time) for our time-to-default model. As mentioned previously, the dependent variable is what we want to predict. However, in survival modeling, a variable is required to identify censoring.

Here we name it censor. Note that there are no survival times greater than 36 months because that's the end of our study period — our censoring limit. Censor is a 0 / 1 variable indicating whether that observation represents a censored account. A censored variable is assigned a value of 0. Otherwise, it gets a value of 1.

The dependent variable is what we want to predict.

A variável dependente é o que se deseja prever.

LGD Models versus Time-to-Default Models

You may consider it good news that the same basic type of regression technique recommended as a possible approach for LGD modeling also can be used, with some variations, for time-to-default modeling. In the economic literature, this type of approach is called a tobit model. In our LGD model, the dependent variable was the percentage of dollars recovered (or not recovered). For a time-to-default model, the dependent variable is the number of months since the point of origin, or how long the account has “survived.”

Figure 2

Modeling Data

Observation	Dependent Variable “Survival Time”	Censoring Variable “Censor”	X1	X2	X3
1	36	0	.72	30	20
2	15	1	.56	45	19
3	20	0	.90	23	45
4	36	0	.90	12	76
5	34	0	.75	4	56
6	36	0	.88	36	12
7	6	1	.90	61	44
8	36	0	.90	22	11

There are a number of ways to estimate a time-to-default model in SAS or any other statistical software package, depending on your assumptions and whether or not your predictor variables change over time (time-dependent attributes). Let’s keep things simple here and work with a SAS procedure called PROC LIFEREG,

Modelos de PCI e Modelos de Tempo até a Inadimplência

Muitas pessoas podem considerar uma boa notícia o fato de que o mesmo tipo básico de técnica de regressão, recomendado como possível abordagem à modelagem de PCI, também pode ser usado, com algumas variações, para a modelagem do tempo antes da inadimplência. Na literatura econômica, abordagens desse tipo são chamadas de modelos *tobit*. Em nosso modelo de PCI, a variável dependente foi a porcentagem de dólares recuperada (ou não recuperada). Para um modelo de tempo até a inadimplência, a variável dependente é o número de meses desde o ponto de origem, ou a duração da “sobrevivência” da conta.

Há diversas maneiras de se estimar um modelo de tempo até a inadimplência no código SAS ou qualquer outro pacote de *software* estatístico, dependendo das premissas adotadas e se suas

Figura 2

Dados de Modelagem

Observação	Variável dependente “Tempo de Sobrevivência”	Variável de Censura “Censor”	X1	X2	X3
1	36	0	0,72	30	20
2	15	1	0,56	45	19
3	20	0	0,90	23	45
4	36	0	0,90	12	76
5	34	0	0,75	4	56
6	36	0	0,88	36	12
7	6	1	0,90	61	44
8	36	0	0,90	22	11

variáveis preditivas variam ou não com o tempo (atributos dependentes do tempo). Vamos simplificar e utilizar um procedimento SAS chamado PROC LIFEREG, que estima uma categoria geral

de modelos chamados modelos de tempo acelerado de falha (*accelerated-failure-time* – AFT). Observe que esse procedimento não permite que as variáveis preditivas mudem com o tempo, o que poderia, em muitos casos, aumentar o poder preditivo. Essa característica, permitida por um procedimento mais complexo chamado de PROC PHREG no SAS, está além do alcance deste artigo. Para os fins de nosso estudo, vamos admitir que os valores das variáveis tenham sido capturados no início do período de estudo e se mantenham inalterados por todo o período de três anos. As Figuras 3 e 4 mostram o código SAS necessário para estimar tanto um modelo de PCI quanto um modelo de tempo até a inadimplência. Usaremos X1, X2 e X3 como variáveis preditivas. Observe-se a semelhança entre os códigos SAS para os dois tipos de modelo.

Na Figura 3, nosso modelo *tobit* de previsão da PCI usa a palavra-chave SAS “LOWER” para tratar um agrupamento em torno de contas que não apresentam recuperação. Como vimos em artigos anteriores, a presença de diversos empréstimos agrupados a uma taxa de recuperação zero poderia causar problemas de modelagem quando se usa regressão linear. O modelo *tobit* foi recomendado como solução possível. Essa questão do agrupamento em torno de um limite inferior (zero, no caso da PCI) é semelhante ao problema da censura no modelo de tempo que precede a inadimplência.

Como se vê na Figura 4, o código SAS para o tempo até a inadimplência é quase idêntico, a não ser pelo fato de que exige o nome da variável de censura e uma designação “0” ou “1” para representar o valor da censura.

which estimates a general class of models called accelerated-failure-time (AFT) models. This procedure, however, does not allow your predictor variables to change over time, which can often enhance your model’s predictive power. That capability, provided by a more complex procedure in SAS called PROC PHREG, is outside the scope of this discussion. For purposes of our discussion, let’s assume the values of the predictor variables were captured at the beginning of the study period and remain unchanged over the three-year period. Figures 3 and 4 show the SAS code necessary to estimate both a LGD and a time-to-default model. We’ll use X1, X2, and X3 as predictor variables. Notice how similar the SAS code looks between the two types of models.

In Figure 3, our tobit model for predicting LGD uses the SAS keyword LOWER to account for a clustering around accounts that show no recovery. As mentioned in previous articles, having a number of loans clustered at a zero recovery rate could cause modeling problems if you were to use linear regression. The tobit model was recommended as one solution. This clustering issue around a lower bound (zero in our LGD case) is similar to our censoring problem in the time-to-default model.

As shown in Figure 4, the SAS code for each time to default looks almost the same, except it requires the name of the censoring variable and a designation of a “0” or “1” to represent the censoring value.

The Hazard Function

In time-to-default modeling, one of the first tasks is to determine the shape of the hazard rate (hazard function) – that is, which distribution to use. To a large extent, this can be done by running the model with a variety of distributions and picking the one with the best fit. One way of doing this

Figure 3

SAS Code for LGD (Tobit Regression)

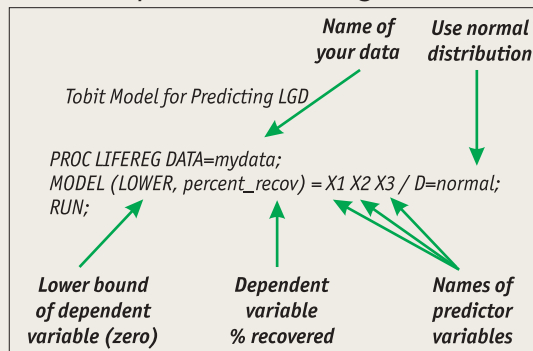
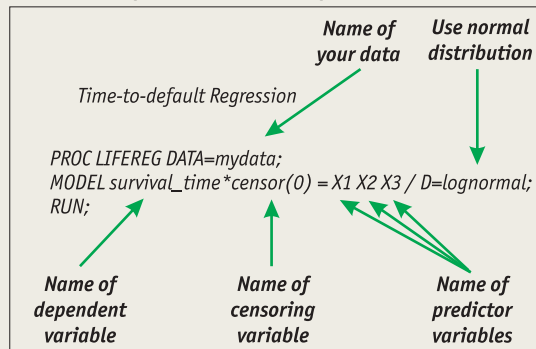


Figure 4

SAS code for Time to Default



is by looking at the log-likelihood value, a statistical measure produced by most software packages. The model with the log-likelihood value closest to zero wins. In Figure 4, we show the use of the lognormal distribution to model the hazard rate. By using this particular distribution, we can even account for a more complex hazard

A Função do Risco

Na modelagem de tempo que precede a inadimplência, uma das primeiras coisas a fazer é determinar o perfil da taxa de risco (função de risco) – ou seja, qual distribuição usar. Em grande parte, isso pode ser feito rodando o modelo com diversas distribuições e escolhendo a que oferece o melhor encaixe. Um jeito de lidar com isso é examinar o valor da probabilidade logarítmica, uma medida estatística produzida pela maioria dos pacotes de soft-

Figura 3

Código SAS da PCI (Regressão Tobit)

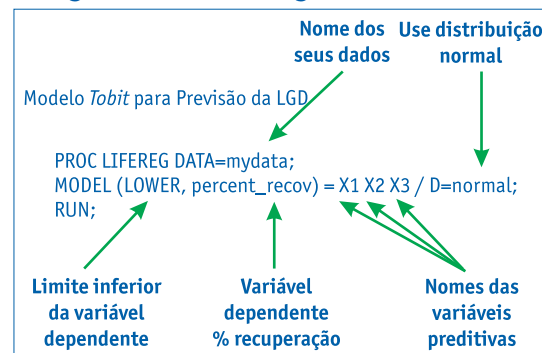
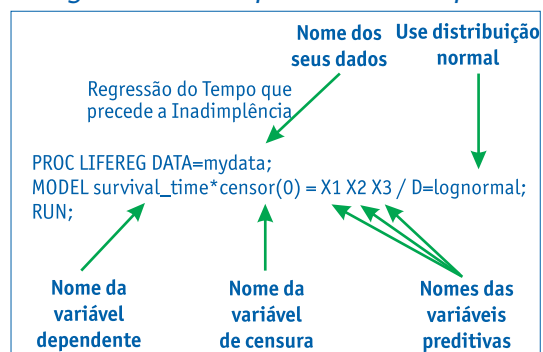


Figura 4

Código SAS do Tempo até a Inadimplência

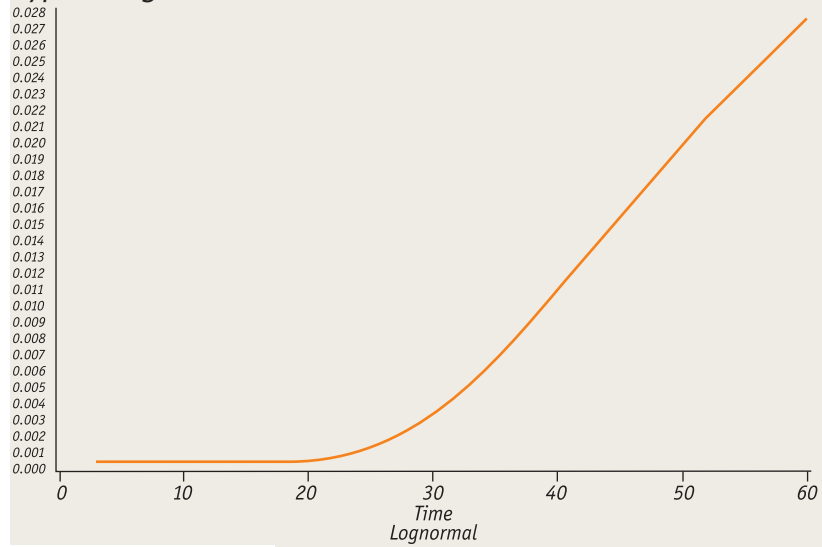


ware. Vence o modelo que tiver probabilidade logarítmica mais próximo de zero. Na Figura 4, mostramos o uso da distribuição logarítmica normal para modelar a taxa de risco. Empregando essa distribuição específica, podemos

até levar em consideração uma taxa de risco mais complexa, capaz de direcionar-se para cima, atingir um pico e até voltar para baixo, dependendo dos dados. Uma taxa de risco logarítmica normal típica pode ser vista na Figura 5. Embora, na verdade, o conceito se aplique melhor ao comportamento de contas individuais, a taxa de risco da Figura 5 é calculada, para os fins do exemplo, usando as médias aritméticas dos dados.

Figure 5


Typical Lognormal Hazard Function



rate that can turn upward, peak, and even turn downward, depending on the data. A typical lognormal hazard rate is shown in Figure 5.

Figura 5

Função Logarítmica Normal Típica do Risco



Although the concept really applies more to the behavior of individual accounts, the hazard rate in Figure 5 is calculated using the simple averages of the data for illustrative purposes.

Prediction and Application

The statistical output of our time-to-default model looks very similar to any other regression model — a set of coefficients for each predictor variable, an intercept, and an estimate of something called SCALE. For the lognormal model, this scale estimate simply stretches or compresses the hazard rate. Once the

Previsão e Aplicação

O produto estatístico de nosso modelo de tempo que precede a inadimplência é bastante parecido com o de qualquer outro modelo de regressão — um conjunto de coeficientes para cada variável

model's coefficients have been estimated, we can do two very useful things.

1. We can make predictions of time to default measured from our point of origin. Although the coding of how these coefficients are used in the prediction formulas is not listed here, it can readily be found in various references². Attention could be focused on those accounts that were predicted to default within the next six months, such as treatment letters or a review of their payment status.

2. We can specify a survival time threshold and calculate the probability that each account would survive up until that point in the future. If you knew there was an 80% chance that your account will survive three more years, you may want to grant some (but maybe not all) increases in their credit lines.

In addition, if there is a contract involved, then this predictive information could be helpful in setting up new terms of the loan.

Summary

The good thing about implementing the modeling requirements for Basel II is that they provide an excellent foundation for establishing sound risk management prac-

predictiva, um intercepto e uma estimativa de algo chamado "SCALE" (ESCALA). No caso do modelo logarítmico normal, essa escala estimada expande ou comprime a taxa de risco. Uma vez estimados os coeficientes do modelo, podemos fazer duas coisas muito úteis.

1. Prever o tempo que precede a inadimplência medido a partir do ponto de origem. Embora o código para a maneira como esses coeficientes são usados nas fórmulas de previsão não seja apresentado aqui, pode ser facilmente encontrado em diversas referências². Pode-se, então, concentrar a atenção nas contas com inadimplência prevista para os seis meses seguintes, com envio de correspondência ou revisão da situação de pagamentos.

2. Especificar um limite de tempo de sobrevivência e calcular a probabilidade de que cada conta sobreviva até tal ponto. Se soubermos que há uma chance de

80% de que uma conta sobreviva por três anos, talvez desejemos conceder aumentos a algumas linhas de crédito (mas não a qualquer uma).

Além disso, se estiver envolvido algum contrato, essas informações preditivas podem ajudar a estabelecer novas condições para o empréstimo.

Sumário

O ponto importante da implementação dos requisitos de modelagem do Novo Acordo da Basileia é que eles constituem uma excelente base para o

Predictive information could set up new terms for the loan.

Informações preditivas estabelecem condições para o empréstimo.

estabelecimento de práticas sólidas de gerenciamento de risco. Essas práticas aplicam-se a todos os estágios do ciclo de vida de uma inadimplência em crédito — da contratação de um empréstimo até a possível inadimplência e cobrança. A modelagem do tempo que antecede a inadimplência permite que a instituição aproveite essa base e, ao mesmo tempo, oferece algumas vantagens claras:

- Lida com dados censurados.
- Evita a rigidez de ter que escolher um período fixo (um ano, por exemplo) de mensuração do desempenho, como no caso dos modelos de PI.
- Oferece maior flexibilidade de incorporação de flutuações econômicas (características dependentes do tempo) ao sistema de *scoring*.
- Prevê os níveis de inadimplência em função do tempo de acordo com diversas taxas de ameaça.
- Pode utilizar grande parte das informações preditivas já encontradas nos armazéns corporativos de dados e usados para relatórios gerenciais, aplicativos de *credit-scoring* e atendimento ao Novo Acordo da Basiléia.

As técnicas referentes ao tempo que precede a inadimplência também podem sofrer ajuste refinado para levar em conta mais do que apenas o tempo que antecede a inadimplência. Por exemplo, em hipotecas residenciais, a análise de sobrevivência é muito usada para considerar, simultaneamente, o tempo anterior ao pagamento antecipado. Isso se faz sob o anteparo dos riscos concorrentes — algo que oferece maior flexibilidade e aplicação prática no setor bancário. Em suma, a modelagem do tempo que precede a inadimplência pode proporcionar aos bancos um mecanismo mais estruturado para elevar as prá-

tices. These practices come at all stages of the credit default life cycle — from booking a loan to possible default and collections. Time-to-default modeling allows the institution to build on this foundation while offering some distinct advantages:

- *It deals with censored data.*
- *It avoids the inflexibility of having to choose a fixed period (one year, for example) to measure performance, as in a PD model.*
- *It allows greater flexibility in incorporating economic changes (time-dependent characteristics) into the scoring system.*
- *It forecasts default levels as a function of time according to a variety of hazard rates.*
- *It can use much of the same predictive information already found in existing corporate data warehouses that are used for management reporting, credit-scoring applications, and Basel II compliance.*

Time-to-default techniques can also be fine-tuned to account for more than just the time to default. For example, in residential mortgages, survival analysis has been used repeatedly to simultaneously account for time to prepayment. This is done under the topic of competing risks — something that offers a great deal of flexibility and practical application in the banking industry. In summary, modeling time to default can allow banks a more structured mechanism for taking standard risk management practices to a new level, moving toward a more quantitative appro-

ach to full profitability analysis – the ultimate bottom line.

Notes

¹MORRISON, Jeffrey S. “Preparing for Modeling Requirements in Basel II Part 1: Model Development,” *The RMA Journal*, May 2003.

²The following publications provide more information on coefficient coding for prediction models:

ALLISON, Paul D. “Survival Analysis Using SAS® System: A Practical Guide”, SAS® Institute Inc., Cary, North Carolina, 1995.

HARREL, Frank E. Jr. “Regression Modeling Strategies with Applications to Linear Models, Logistic Regression, and Survival Analysis”, Springer-Verlag, New York, Inc., 2001.

EDELMAN, Thomas et al. “Credit Scoring and Its Applications, Society for Industrial and Applied Mathematics”, 2002.

2004 RMA. Jefferson Morrison was vice-presidente Credit Metrics-PRISM Team, at Suntrust Banks Inc., Atlanta, Georgia. Morrison is currently senior manager Modeling Services for Transunion LLP in the Atlanta Georgia office. Transunion builds modeling solutions for both credit risk and marketing applications in addition to their core credit bureau products. Contact Morrison at m_jeffer@bellsouth.net
RMA - Risk Management Association is an international association of financial services professionals. For membership information, e-mail acauley@rmahq.org ; to subscribe to *The RMA Journal*, visit www.rmahq.org/Ed_Opps/pubs/journalad.htm

ticas de gerenciamento de risco a um novo nível, adotando uma abordagem mais quantitativa à análise de lucratividade como um todo — que é o que realmente importa.

Notas

¹MORRISON, Jeffrey S. “Preparing for Modeling Requirements in Basel II Part 1: Model Development,” *The RMA Journal*, Maio de 2003.

²As publicações abaixo fornecem maiores informações sobre a codificação de coeficientes para modelos preditivos:

ALLISON, Paul D. “Survival Analysis Using SAS® System: A Practical Guide”, SAS® Institute Inc., Cary, Carolina do Norte, 1995.

HARREL, Frank E. Jr. “Regression Modeling Strategies with Applications to Linear Models, Logistic Regression, and Survival Analysis”, Springer-Verlag, Nova York, Inc., 2001.

EDELMAN, Thomas et al. “Credit Scoring and its Applications, Society for Industrial and Applied Mathematics”, 2002.

2004 RMA. Jefferson Morrison foi vice-presidente de Medidas de Crédito – Equipe PRISM do Suntrust Banks Inc., Atlanta, Georgia. Atualmente ele é gerente sênior de Serviços de Modelagem do Transunion LLP em Atlanta, na Georgia. A Transunion constrói soluções em modelagem tanto para risco de crédito como para aplicações em marketing em seu escritório central de produtos de crédito. Os contatos com Jefferson Morrison podem ser feitos pelo E-mail m_jeffer@bellsouth.net
A RMA - Risk Management Association é uma associação internacional de profissionais de serviços financeiros. Para informações, e-mail acauley@rmahq.org ; Para assinar *The RMA Journal* visite o site www.rmahq.org/Ed_Opps/pubs/journalad.htm