

Controle Total do Risco na Empresa: Não Omitir a Função de Marketing

The Basel toolbox already has proven to have more than one application. Financial institutions can make even greater use of this resource by adapting information for marketing purposes. Moving from quant to marketer may not be such a stretch in institutions using an enterprise approach to risk and growth.

In financial institutions, as with any business, it is a challenge to grow an existing portfolio while controlling inherent levels of risk. And, in an enterprise environment, risk can take a variety of forms. While credit risk lenders' core risk discipline, a financial institution's profitability depends on effective control of risks across the enterprise.

Quantitative analysis plays a primary role in controlling risk, especially from the regulators' point of view. The New Basel Capital

Jeffrey S. Morrison

Susan Alvarez

Controlling Risk Across an Enterprise: Don't Forget the Marketing Function

A caixa de ferramentas da Basileia já demonstrou ter mais de uma aplicação. As instituições financeiras podem utilizar mais intensamente esse recurso por meio da adaptação de informações para fins de *marketing*. Passar de quantificador para profissional de *marketing* pode não ser tão difícil em instituições

que usem uma abordagem global ao risco e ao crescimento.

Nas instituições financeiras, como em qualquer empresa, incrementar uma carteira existente ao mesmo tempo em que se controlam os níveis de risco inerentes é um desafio. E, num ambiente empreendedor, o risco pode assumir diversas formas. Embora o risco de crédito seja o núcleo da disciplina de risco dos credores, a lucratividade de uma instituição financeira depende de controle efetivo sobre todos os riscos da empresa.

A análise quantitativa desempenha uma função central no controle do risco, especialmente do ponto de vista dos reguladores. O Novo Acordo

de Capital da Basileia deixa isso bem claro:

“O princípio geral por detrás dessas exigências é o de que os sistemas e processos de rating e estimativa de risco forneçam uma avaliação relevante das características do devedor e da transação; uma diferenciação significativa do risco; e estimativas quantitativas de risco razoavelmente precisas e consistentes.”

O Novo Acordo de Capital da Basileia
26 de junho de 2004

Mas a análise quantitativa também pode contribuir significativamente para o crescimento dos negócios. O fato é que a avaliação quantitativa do risco faz sentido do ponto de vista empresarial. O mesmo se pode dizer do aspecto de *marketing*. Afinal, na maioria das organizações, a função de *marketing* assume como papel principal o gerenciamento do risco estratégico ou competitivo. O *marketing* pode aplicar as técnicas analíticas usadas pela gestão de risco ao crescimento da carteira identificando: 1) os clientes atuais com maior probabilidade de comprar mais produtos e 2) os que provavelmente recorrerão mais rapidamente à concorrência.

Considere um analista que tenha trabalhado por diversos anos na área de Gestão de Risco e desenvolvido modelos quantitativos para fazer com que as carteiras de crédito ao consumidor atendam ao novo Acordo. Esse empregado deve ser capaz de transferir seu conhecimento a uma nova posição em *marketing* no banco. É claro que uma mudança de carreira de Gestão de Risco para a Divisão de *Marketing* exigiria um certo aprendizado; mas a experiência quantitativa

Accord makes this very clear:

“The overarching principle behind these requirements is that rating and risk estimation systems and processes provide for a meaningful assessment of borrower and transaction characteristics; a meaningful differentiation of risk; and reasonably accurate and consistent quantitative estimates of risk.”

*The New Basel Capital Accord
June 26, 2004*


Yet quantitative analysis can make a significant contribution to business growth as well. Quantitative risk assessment simply makes a good business sense. The same can be said on the marketing side of the enterprise. After all, in most organizations, the marketing function assumes the primary role of managing strategic or competitive risk. Marketing can apply the analytic techniques used by risk management to portfolio growth by identifying 1) those current customers most likely to purchase additional products and 2) those likely to turn to the competition most quickly.

Consider a bank associate who has worked in Risk Management for a number of years and has built quantitative models to bring the bank’s consumer portfolios into compliance with the new Accord. This employee should be able to transfer his or her knowledge into a new marketing role within the bank. Certainly, a career shift from Risk Management to the Marketing Division would require a bit of a learning curve; however, the

associate's quantitative experience will play a huge role in such areas like helping to grow the consumer credit card business, determining how better to up-sell existing customers, and developing a segmentation strategy for an existing portfolio.

Regression and other Basel II tools can be used to create marketing tools, such as a road map to a prospect list that is ranked in order of those most likely to respond to a mailing. After all, the very foundation of such a technique is based on known statistical properties and sampling distributions that help determine whether a piece of predictive information is truly "statistically significant."

Under the Basel Accord, a primary objective might be to build a probability of default (PD) model that predicts payment default, based on information such as loan to value (LTV), credit score, recent payment history, and time-on-books. On the recovery side, another type of regression tool might help determine the amount of percentage that could be recovered from an account if a default were to occur. When these tools are used in the context of meeting marketing objectives, they fall



do analista será de enorme utilidade em áreas como ajudar a aumentar o negócio de cartões de crédito, determinar a melhor maneira de incrementar as vendas para clientes atuais e desenvolver uma estratégia de segmentação para uma carteira existente.

A regressão e outras ferramentas do Novo Acordo podem ser usadas para criar instrumentos de marketing, como por exemplo um "mapa" contendo uma lista de clientes prospectivos por ordem dos que têm maior probabilidade de responder a uma mala direta. Afinal de contas, as bases dessa

PENINHA técnica estão assentadas em propriedades estatísticas e distribuições de amostragem conhecidas que ajudam a determinar se um elemento de informação preditiva é, de fato, "estatisticamente significativo".

Nos termos do Acordo da Basileia, um dos principais objetivos poderia ser a construção de um modelo de probabilidade de inadimplência (PI) que preveja a inadimplência em pagamentos com base em informações como *loan to value* (LTV), *score* de crédito, histórico de pagamentos recente e tempo nos livros do banco. Do lado da recuperação, outro tipo de ferramenta de regressão ajudaria na determinação do montante ou percentual a ser recuperado de uma conta se ela se tornasse inadimplente. Quando essas ferramentas são usadas no contexto da consecução de objetivos

de *marketing*, encontram-se sob o pálio amplo do *database marketing*.

De modo geral, o *database marketing* é “a arte e a ciência” de visar clientes em potencial de um determinado produto ou serviço. É uma arte porque não há uma solução pronta que sirva para o objetivo de *marketing* de todas as empresas. E é uma ciência porque usa uma biblioteca de técnicas estatísticas para minar dados com eficácia e escolher os clientes mais adequados a um esforço de *marketing* específico. A maior

parte das atividades de *database marketing* procura atingir objetivos semelhantes para a empresa, identificando, por exemplo:

- Que clientes incluir numa campanha de mala direta para incrementar uma dada carteira.
- Quais clientes são os melhores candidatos a maiores vendas ou à venda cruzada de um produto ou serviço.
- Como atingir a fidelização ideal de clientes.

Desenvolvimento de um Modelo de Resposta

Como vimos em artigos anteriormente publicados, é fácil desenvolver modelos de regressão. Mas é preciso dispor do tipo certo de dados se o *marketing* quiser usar esses modelos para aumentar uma base de clientela. Independentemente da área funcional, o objetivo empresarial é o mesmo — quantificar as diferenças entre duas popula-

under the broader umbrella of database marketing.

Generally, *database marketing* is the “art and science” of targeting potential customers for a given product or service. It is an art because there is no one-size-fits-all approach that works for every company’s marketing objective. It is a science because it uses a library of statistical techniques to mine the data effectively and to select those

customers best suited for a particular marketing effort. Most *database marketing* activities seek to achieve similar objectives for the business, identifying, for example:

- Which customers to include in a direct-mail campaign to grow an existing portfolio.
- Which customers are the best candidates for up-selling or cross-selling a product or service.
- How to achieve optimal customer retention.

A análise quantitativa pode contribuir para o crescimento dos negócios.

Quantitative analysis can make a contribution to business growth.

Developing a Response Model

As discussed in past RMA Journal articles, regression models are easy to develop. However, for Marketing to use them to grow a customer base requires the right kind of data. Regardless of the functional area, the business objective is the same — to quantify the differences between two populations

by using historical information.

- *First, conduct a random test mailing of potential prospects — perhaps tempered by a credit score. The anticipated response rate is crucial in determining the amount of test mailings. For example, if the expected response rate is 1%, then 500 responses would come from a mailing of 50,000. In the risk world, working with 500 defaults might be considered the bare minimum required to build a PD model. The same is true for marketing. Typically, at least 2,000 responders are needed for model-building and validation purposes.*

- *After mailings have been sent out and responses collected, this information can be combined with other data — such as demographics, income, and past credit characteristics — for regression-modeling purposes. Predictive tools of this kind are often referred to as response models.*

- *Now it is time to build the response model. Under Basel, a risk manager would be building a PD model where the default event might be determined over a one-year performance window. In marketing, the time it takes for the majority of customers to respond to a mailing determines the “performance window” — usually only one or two months. This is the primary difference between the two model-building practices — the performance window for risk is typically much longer. Other than that, a marketing manager would use the exact same model-building approach as suggested in the checklist discussed in*

ções por meio do uso de informações históricas.

- *Inicialmente faz-se uma mala direta aleatória — possivelmente temperada por um score de crédito — para testar prospectos em potencial. A taxa prevista de resposta é crucial para determinar a quantidade de correspondências a serem enviadas. Por exemplo, se a taxa esperada de resposta for de 1%, então viriam 500 respostas a partir de uma mala direta de 50.000. No mundo do risco, trabalhar com 500 inadimplências poderia ser considerado o mínimo necessário para construir um modelo de PI. O mesmo se aplica ao marketing. Normalmente são necessários pelo menos 2.000 respostas para os fins de construção e validação do modelo.*

- *Após o envio da mala direta e a captação das respostas, essas informações podem ser combinadas com outros dados — como aspectos demográficos, renda e características históricas de crédito — para os fins da modelagem por regressão. Ferramentas preditivas dessa espécie são frequentemente chamadas de modelos de resposta.*

- *Agora é hora de construir o modelo de resposta. Nos termos do Acordo da Basileia, um gestor de risco deveria construir um modelo de PI em que o evento de inadimplência fosse determinado ao longo de uma janela de desempenho de um ano. Em marketing, é o tempo que leva para a maioria dos clientes responder a uma mala que determina a “janela de desempenho” — normalmente de um ou dois meses. Essa é a principal diferença entre as duas práticas de construção de modelos — a janela de desempenho do risco costuma ser muito maior. Salvo por esse detalhe, um gestor de marketing usaria exatamente a mesma abordagem à construção de modelos sugerida na*

checklist que vimos em artigos anteriores.

1. Definir sua variável preditiva (dependente). A variável tem valor 1 se o cliente destinatário respondeu; e valor 0 caso contrário.

2. Definir a janela de desempenho, correspondente ao tempo necessário para enviar a mala direta e obter resposta da maioria das pessoas — repetindo, um prazo de um a dois meses, normalmente.

3. Determinar o tamanho da amostra de seu modelo preditivo. Se tiver 2.000 respostas, divida os dados, separando 75% para a construção do modelo e 25% para sua validação.

4. Atribua a cada registro os atributos que acredita poderem ser preditivos, se ainda não o tiver feito.

5. Examine a informação em busca de pontos de dados fora do normal. Faça os gráficos das distribuições e analise suas correlações umas com as outras e com sua variável preditiva.

6. Trate dos dados faltantes. Substitua valores de atributos preditivos faltantes por médias aritméticas etc.

7. Use regressão logística para estimar o modelo preditivo.

8. Examine os sinais de cada ponderação preditiva produzida pelo procedimento de regressão. Certifique-se de que ele faz sentido.

9. Calcule as probabilidades previstas a partir de seu modelo de regressão com as amostras de desenvolvimento e validação e classifique-as da maior para a menor. As observações dos 20% superiores da lista serão os prospectos com maior probabilidade de responder à sua campanha promocional.

10. Faça o *score* de sua nova *mailing list*. Ou

earlier RMA Journal articles:

1. *Define your prediction (dependent) variable. A variable with a value of 1 if the customer that was mailed responded; otherwise, a value of 0 is assigned.*

2. *Define the performance window. This is the time it takes for the mailing to go out and the majority of people to respond — again, usually one to two months.*

3. *Determine the sample size for your predictive model. If you have about 2,000 responders, split your data into 75% for building the model and 25% for validating it.*

4. *Attach the attributes you think might be predictive to each record if you haven't already.*

5. *Examine the information for unusual data points. Graph the distributions and analyze their correlations with each other and your prediction variable.*

6. *Account for missing data. Substitute sample averages for missing predictive attribute values, etc.*

7. *Use logistic regression to estimate the predictive model.*

8. *Examine the signs of each predictive weight produced by the regression procedure. Make sure it makes sense.*

9. *Calculate the predicted probabilities from your regression model on your development and validations sample and rank them from highest to lowest. The observations in the top 20% of the list are those prospects most likely to respond to your promotional campaign.*

10. *Score your new mailing list. This me-*

ans use the algorithm from your regression to identify your most likely prospects with a mailing that is now based upon much better marketing intelligence and contains a high degree of information content. This will give you a list, which is rank ordered from high to low – a list that should be mailed from top to bottom based on the budgetary dollars associated with the campaign.

Developing a “Look-alike” Model

Marketing budgets often do not support the expense of random test mailings resulting in a 1% response rate. Another methodology for these instances is often referred to as a prospect or a look-alike model. By using the same technique from the Basel toolbox, this model predicts the chances that a potential prospect “looks like” a customer you already have. Rather than measuring response to any upcoming promotional campaign, it reflects this thought: “If this customer were to respond to our mailing, he or she would tend to look like one of our best customers.” The criteria to identify these best customers might come from an RFM analysis – an evaluation of their accounts in terms of recency of purchase, frequency of the purchasing habits,

seja, use o algoritmo de sua regressão para identificar os prospectos mais prováveis com *mailing* que, agora, se baseia em inteligência de *marketing* de muito melhor qualidade e contém elevado teor de informação. Isso resultará em uma lista que é uma classificação por ordem decrescente que deve ser usada de cima para baixo de acordo com o orçamento de cada campanha.

A regressão é usada para criar ferramentas de marketing.

Regression is used to create marketing tools.

Desenvolvimento de um Modelo “Dublê”

Os orçamentos de marketing muitas vezes não são capazes de suportar a despesa de testes de mala direta que apresentam um índice de respostas de 1%. Outro método que pode ser usado é muitas vezes chamado de modelo de prospecto, ou modelo *dublê*. Usando a mesma técnica da caixa de ferramentas da Basileia, esse modelo prevê a probabilidade de que um prospecto em potencial seja semelhante a um cliente que você já tem. Em vez de medir a resposta a qualquer campanha promocional vindoura, esse método reflete o seguinte raciocínio: “Para um cliente prospectivo responder à nossa mala direta, ele deveria se assemelhar a um dos nossos melhores clientes.” Os critérios usados para identificar esses melhores clientes podem vir de uma análise de RFM – uma avaliação das contas em termos do quanto são recentes, da frequência de seus hábitos de com-

pra e do valor monetário associado.

Como anteriormente, precisamos de informações sobre duas populações:

- A primeira iniciativa é obter uma lista das “melhores” contas. Para um modelo *dublê*, a variável preditiva usada na regressão assume valor 1 se a conta for uma das “melhores”.

- Em seguida, obtenha uma lista de prospectos aleatoriamente reduzida para aproximadamente o mesmo número de contas “melhores” da análise anterior.

- Anexe a lista de prospectos à de melhores contas para representar a segunda população de indivíduos que ainda não são clientes do banco. Para essas contas a variável preditiva assumirá valor 0.

O processo de construção de modelo seria o mesmo usado para um modelo de resposta, em que se faz uma regressão logística e o algoritmo resultante é usado para fazer o *score* dos novos prospectos e os classificar em ordem decrescente para os fins da campanha de *marketing*.

Desenvolvimento de Oportunidades de Venda Cruzada

Até aqui, a discussão lidou com a obtenção de novos clientes. Mas e quanto às contas que já existem? Como lhes vender mais produtos ou serviços?

and the associated monetary value.

As before, information on two populations is needed.

- First, obtain a list of the “best” accounts. For a look-alike model, the prediction variable used in the regression take on a value of 1 if that account represented a “best” account.

- Next, obtain a prospect list, randomly sampled down to about the same number of “best” accounts in the analysis.

- Append the prospect list to the best accounts list, to represent the second population of individuals who are currently not customers of the bank. For those accounts, the prediction variable would take on a value of 0.

The model-building process would be the same as for a response model in which a logistic regression is performed and the resulting algorithm is then used to score new prospects and rank-order them from high to low for the marketing campaign.

Developing Cross-Sell Opportunities

The discussion so far has dealt with getting new customers. What about those accounts that already exist? How can you sell them more products or services?

Informações históricas quantificam a diferença entre duas populações.

Historical information quantifies the differences between two populations.

For a common banking scenario of selling more home equity loans to an existing customer base, marketers can — once again — turn to the Basel toolbox to design an effective cross-sell strategy. As before, the differences between two populations need to be established. For this scenario, the populations would be those who have a mortgage with the bank as well as a home equity loan, and those who are simply mortgage customers with no home equity product. Since the bank already has this data on both groups, a cross-sell model could be built quickly with internal data or expanded to include additional demographic data sources, which could further increase the model's predictive power.

- *The prediction variable for the regression is created where the account has a value of 1 if it is both a mortgage customer and has a home equity loan.*
- *For those accounts with no home equity loans, the prediction variable takes on a value of 0.*

The model-building process would follow the same pattern of performing a logistic regression and using the resulting algorithm to score existing accounts. The score would reflect the account's chances that it resembled or "looked like" a candidate for cross-selling the home equity product. A high score would reflect a relatively higher chance of cross-selling; a low score would mean the chances of an effective cross-selling attempt would be small.

Num cenário comum em bancos, de venda de mais empréstimos garantidos pela casa própria a uma base de clientela existente, os gerentes de *marketing* podem — mais uma vez — recorrer à caixa de ferramentas da Basiléia para conceber uma estratégia eficaz de venda cruzada. Como nos casos anteriores, é preciso estabelecer as diferenças entre as duas populações. Nesse cenário, as populações são representadas pelos que têm hipoteca contratada com o banco e empréstimo garantido pela casa própria, de um lado, e, de outro, aqueles que são apenas clientes hipotecários e não têm produto garantido pelo imóvel. Como o banco já dispõe dos dados sobre os dois grupos, um modelo de venda cruzada poderia ser construído rapidamente a partir dos dados internos ou expandido para abranger fontes adicionais de dados demográficos, o que ampliaria o poder preditivo do modelo.

- A variável preditiva da regressão é criada quando a conta tem valor 1 se for tanto cliente com hipoteca quanto cliente de empréstimo garantido pela casa própria.
- Para as contas sem empréstimos desse tipo, a variável preditiva assume valor 0.

O processo de construção de modelo seguiria o mesmo padrão, realizando uma regressão logística e usando o algoritmo resultante para fazer o *score* das contas existentes. O *score* refletiria a probabilidade de que a conta se assemelhasse (ou fosse *dublê*) a uma candidata para a venda do produto garantido pela casa própria. Um *score* elevado refletiria uma chance relativamente maior de venda cruzada; um *score* baixo significaria que a probabilidade de venda cruzada eficaz seria baixa.

Fidelização de Clientes

Como o custo de obter uma nova conta costuma ser muito mais elevado do que o de manter contas existentes, a maioria das empresas tem interesse em implementar algum tipo de programa de retenção da clientela. Na área de comunicação sem fio, o giro é um problema enorme; os profissionais de *marketing* estão sempre tentando impedir que seus clientes passem para um concorrente por motivos que não se refiram a preço. No mundo das hipotecas, um aumento do número de devedores que decida quitar antecipadamente seu saldo remanescente terá um efeito dramático sobre as projeções financeiras do banco. Se o banco puder prever antecipadamente quais clientes têm maior chance de optar pela quitação antecipada, poderão rever os termos do crédito, tornando-o mais lucrativo.

Num artigo publicado no RMA Journal em 2004, foi apresentado outro tipo de regressão, chamado “análise de sobrevivência”, para ajudar as instituições financeiras atender às diretrizes reguladoras do Novo Acordo de Capital da Basileia. Essa ferramenta se concentrava na previsão do momento em que ocorreriam as inadimplências, mas também pode ser usada pelo *marketing* para prever o prazo até o pagamento antecipado numa carteira hipotecária residencial em que a retenção de contas seja uma meta estratégica importante.

A análise de sobrevivência usa um tipo especial de regressão particularmente adequado a lidar com um tipo de dado que é, freqüentemente, empregado em estudos de retenção de clientes — os dados censurados, que trazem implícita uma lacuna informacional. Por exemplo, não sabemos

Establishing Customer Loyalty

Because the cost of obtaining a new account is typically much larger than that for keeping existing ones, most companies are very interested in implementing some type of customer retention program. In wireless telecommunications, churn is a huge problem; marketers are constantly trying to keep their current customers from switching to a competitor for reasons other than price. In the mortgage world, a rise in loan customers who decide to pay off their remaining balance early will have a dramatic impact on the bank's financial forecasts. If the bank could anticipate early on those customers who were expected to opt for a prepayment alternative, a lender could revise the terms of the loan, making it more profitable to the bank.

In a 2004 RMA Journal article, another type of regression procedure called survival analysis was introduced to help financial institutions meet The New Basel Capital Accord regulatory guidelines. The focus of this tool would be on predicting the timing of payment defaults. This tool also can be used in marketing to predict time-to-prepayment for a residential mortgage portfolio where account retention is an important strategic goal.

Survival analysis uses a specialized type of regression uniquely suited for dealing with the type of data often applied in customer retention studies — censored data. Censored data implies an information gap. For example, we don't know the status of the prediction variable once it

advances past a certain point in time within the study period. In the mortgage example for predicting prepayment, we could track a collection of accounts over a three- to five-year period and count how many months (or quarters) they have “survived” without paying a loan off early. Factors predicting this behavior might be loan size, credit score, LTV, loan term, interest rate, local economic conditions, indicators for a first or second mortgage, current coupon for ARMs, prepayment penalty indicators, age of the loan, and other demographic information.

As with all the other tools discussed in this article, survival analysis requires a prediction variable – in this case, the length of time an account has gone (survived) without prepayment. The output from the study can be divided into two parts:

- 1. The probability that the account will not prepay over a specific period of time.*
- 2. The actual number of months (or quarters) that the account will survive – that is, not prepay.*

Both predictive aspects of survival analysis can be used in marketing to proactively offer customer retention incentives

qual o estado da variável preditiva uma vez superado um determinado ponto no tempo dentro do período em estudo. No exemplo da previsão do pagamento antecipado de hipotecas, poderíamos acompanhar o recebimento de contas ao longo de um período de três a cinco anos e contar por quantos meses (ou trimestres) as contas “sobreviveram” sem quitação antecipada. Os fatores preditivos desse comportamento poderiam ser o porte do empréstimo, o *score* de crédito, o LTV, o prazo do empréstimo, a taxa de juros, as condições econômicas do local, indicadores de primeira ou segunda hipoteca, o cupom atual dos ARMs, indicadores de penalidades por quitação antecipada, idade do empréstimo e outras informações demográficas.

Como todas as demais ferramentas discutidas neste artigo, a análise de sobrevivência exige uma variável preditiva — nesse caso, quanto tempo uma conta durou (sobreviveu) sem quitação antecipada. O resultado do estudo pode ser dividido em duas partes:

1. A probabilidade de que a conta não seja quitada por um prazo específico.
2. O número efetivo de meses (ou trimestres) pelos quais a conta sobreviverá — ou seja, não será quitada.

Os dois aspectos preditivos da análise de sobrevivência podem ser usados no marketing para oferecer incentivos à retenção de clientela antes

Companies are interested in customer retention programs.

Empresas se interessam por programas de retenção de clientes.

que ocorra uma quitação, além de fornecer insumos para modelos de carteira usados para projeções de receita e lucratividade.

Sumário

Este artigo destacou apenas algumas das áreas em que o conhecimento de técnicas estatísticas obtido durante o atendimento às diretrizes reguladoras do novo Acordo pode ser facilmente traduzido para o mundo do *marketing*. De fato, essas abordagens quantitativas podem ser aplicadas em todo o espectro da gestão global de risco. Os objetivos empresariais do *marketing* são diferentes dos da gestão tradicional de risco de crédito — mas não menos importante. Outras técnicas estatísticas avançadas, como CHAID, redes neurais e modelos de série temporal de corte longitudinal podem ser facilmente usados pelos profissionais de *marketing* para identificar novos prospectos, desenvolver esquemas de segmentação produzir maiores oportunidades de venda cruzada e até mesmo medir o impacto agregado de uma mudança do ambiente econômico sobre a carteira de varejo de um banco.

Os artigos aqui referenciados pertencem principalmente à série "Preparativos para o Novo Acordo da Basileia," por Jeffrey S. Morrison, que foram publicados nas edições 43, 44, 45, 46 da Revista Tecnologia de Crédito.

before prepayment might occur, as well as provide input into portfolio models for revenue and profitability projections.

Summary

This article has highlighted just a few areas where knowledge of statistical techniques gained in support of meeting the regulatory guidelines for the new Accord can easily translate across the enterprise and into the world of marketing. Indeed, these quantitative approaches can be applied across the spectrum of enterprise risk management. The business objectives for marketing are different from those of traditional credit risk management — but of no less importance. Other advanced statistical techniques, such as CHAID, neural networks, and pooled cross-section time-series models, can easily be used by marketers to identify new prospects, develop segmentation schemes, produce greater cross-sell opportunities, or even measure the aggregate impact of a changing economic environment on a bank's retail portfolio.

A análise de sobrevivência exige uma variável preditiva.

Survival analysis requires a prediction variable.

© 2005 RMA. Jeffrey Morrison is Senior Manager of Analytics for TransUnion where his role includes leading the Research and Development initiatives of the organization as well as special projects in Econometrics. Jeff graduated from Georgia Institute of Technology with degrees in Economics and Management and then earned a Masters of Science in Business Economics from Georgia State University. His professional career in analytics spans a number of industries including Natural Gas Distribution, Telecommunications, Consumer Credit, and Commercial & Retail Banking. Jeff has spoken in numerous conferences throughout the United States on subjects related to statistical modeling and forecasting, and has published over 30 articles in applied Journals. Jeff can be contacted at jmorrison@transunion.com.

Susan Alvarez is Senior Manager of Analytical with over 20 years of experience in statistical modeling and data analysis/mining for financial services, insurance, publishing, telecommunications, catalog and continuity clubs. Susan has extensive experience building both customized and generic consumer segmentation systems. She has also developed scoring models to predict consumer bankruptcy, credit and insurance risk, response/conversion, cross-sell, and customer value and retention. Susan holds a M.S. degree in Management/Market Research from the School of Management at the Georgia Institute of Technology and a B.A. degree cum laude in Economics from Mount Holyoke College. Susan is fluent in Spanish and can be contacted at smalvar@transunion.com

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

© 2005 RMA. Jeffrey S. Morrison é Gerente Sênior da TransUnion, LLC em Atlanta, Geórgia, onde lidera a função de Pesquisa e Desenvolvimento de análises e trata de projetos especiais de Econometria. Jeff formou-se pelo Georgia Institute of Technology, com graduação em Economia e Administração, e obteve seu mestrado em Economia Empresarial pela Georgia State University. Sua carreira profissional de análise abrange diversos setores, inclusive distribuição de gás natural, telecomunicações, crédito ao consumidor e bancos comerciais e de varejo. Jeff proferiu palestras em diversas conferências sobre modelagem estatística e previsão em todos os Estados Unidos e já publicou mais de 30 artigos em periódicos especializados. Entre em contato com Jeff no endereço j_morrison@transunion.com

Susan Alvarez é Gerente Sênior de Análises e tem mais de 20 anos de experiência em modelagem estatística e análise/mineração de dados para serviços financeiros, seguros, editoras, telecomunicações e clubes de compras e fidelidade. Susan tem larga experiência na construção de sistemas de segmentação de consumidores, sejam customizados ou genéricos. Ela também desenvolveu modelos de scoring para prever insolvência de consumidores, risco de crédito e de seguro, resposta/conversão, venda cruzada e valor e retenção de clientes. Susan é Mestre em Administração/Pesquisa de Mercado pela Escola de Administração do Georgia Institute of Technology e Bacharel (cum laude) em Economia pelo Mount Holyoke College. Susan é fluente em espanhol e pode ser contatada no endereço smalvar@transunion.com

RMA - Risk Management Association é uma associação internacional de profissionais de serviços financeiros. Para informações sobre filiação, envie e-mail para acauley@rmahq.org. Para assinar o RMA Journal, visite www.rmahq.org/Ed_Opps/pubs/journalad.htm