

Collection Score e as Oportunidades no Mercado de *Non-Performing Loans*

Collection Score and the Opportunities for Non-Performing Loans Market

Recebido: 26/09/2021 | Aceito: 18/12/2021 | Publicado: 20/12/2021

Eric Bacconi Gonçalves¹

 <https://orcid.org/0000-0003-4908-1246>

 <http://lattes.cnpq.br/6967644742885730>

Centro Universitário das Faculdades Metropolitanas Unidas, FMU, Brasil

E-mail: Ebacconi@gmail.com

Francisco Carlos Barbosa dos Santos²

 <https://orcid.org/0000-0003-3003-1222>

 <http://lattes.cnpq.br/2824313950877049>

Centro Universitário Alves Faria, UNIALFA, Brasil

E-mail: fcarlos@usp.br

Paulo César Bontempo³

 <https://orcid.org/0000-0002-5694-5762>

 <http://lattes.cnpq.br/7391840846575335>

Centro Universitário Alves Faria, UNIALFA, Brasil

E-mail: paulo.bontempo@unialfa.com.br

Resumo

Na literatura acadêmica, modelos aplicados à área de crédito (chamados de *credit scoring*) são largamente explorados, ao passo que modelos aplicados à cobrança (chamados de *collection scoring*) são pouco abordados; da mesma maneira existem poucos artigos que tratam o mercado brasileiro de empréstimos bancários não pagos ou mais comumente chamados de *non-performing-loans*. Este trabalho traz como principais contribuições: a utilização de modelos de *scoring* na área de Cobrança, e trabalhar com dados *non-performing-loans*. O objetivo deste trabalho é, desenvolver um modelo de *collection scoring* por intermédio de Regressão Logística para identificar, em uma carteira de clientes com “créditos podres”, para verificar a possibilidade ajustar um bom modelo com altas taxas de acerto e apontar quais clientes têm maior propensão de pagar os créditos não performados. Os resultados mostram que o modelo funcionou bem para o público testado, obtendo um excelente ajuste (taxa de acerto superior a 83% nas amostras de desenvolvimento e de validação; KS de 68), apontando a viabilidade de sua aplicação.

Palavras-chave: *Non-performing loans*. *Collection Scoring*. Regressão Logística. Modelos Estatísticos. Cobrança.

¹ Graduando em Estatística pela Universidade Estadual de Campina (UNICAMP), Mestre e Doutor em Administração de Empresas pela Universidade de São Paulo (USP).

² Graduado em Economia pela Universidade de São Paulo. Mestre em Economia pela Univesité Pierres Mende France (UPMF – Grenoble, Mestre em Desenvolvimento e Energia pelo Instituto de Pesquisas Energéticas e Nucleares da USP, Doutor em Administração de Empresas pela Universidade de São Paulo (USP).

³ Graduado em Economia pela Universidade de São Paulo (USP); Mestre e Doutor em Administração de Empresas pela Universidade de São Paulo (USP).

Abstract

In the academic literature, credit scoring models are widely studied, while collection scoring models are less explored; likewise, there are few articles dealing with the Brazilian non-performing-loans market. This work has as main contributions: the use of scoring models in the area of collection and working with non-performing-loans data. The objective of this paper is to develop a collection scoring model through Logistic Regression to identify, in a portfolio of clients with non-performing-loans, to verify if it is possible to adjust a good model and to indicate which clients are more likely to pay the debts nonperforming credits. The results show that the model worked well for the database, obtaining an excellent fit (accuracy of classification greater than 83% for the two samples and $KS=68$), pointing the viability of this methodology.

Keywords: *Non-performing loans. Collection Scoring. Logistic Regression. Statistical Models.*

1. Introdução

A partir de 1994, pós estabilização financeira advinda do Plano Real, o mercado brasileiro passou a se valer de modelos de análise para crédito massificado, avaliando grandes volumes de propostas de forma automática (GONÇALVES; GOUVÊA; MANTOVANI, 2013). Anteriormente, uma solicitação de crédito era avaliada por um ou mais analistas que examinavam a proposta preenchida por um proponente. Um processo eficaz, no sentido de assertividade, porém, lento, e que não permitia a análise de muitos pedidos. Neste sentido, a adoção dos modelos estatísticos, junto com a facilidade computacional, veio justamente para acelerar a tomada de decisões permitindo às instituições financeiras maior agilidade na avaliação de propostas.

A partir do início dos anos 2000, este processo se acelera e, as instituições financeiras brasileiras começam a se valer de forma maciça dos modelos quantitativos como suporte às decisões de concessão de crédito (BRITO; ASSAF NETO, 2008), devido à estabilidade da moeda, alcançada no Plano Real, a qual trouxe altas taxas de crescimento no volume de crédito ao consumidor (FONSECA et al., 2019). Com a maturidade da utilização dos modelos de avaliação de crédito, as instituições perceberam que esta ferramenta de análise pode ser utilizada também para outros ciclos da administração de contas a receber (FERREIRA; CELSO; BARBOSA NETO, 2012). Cabe destacar ainda, segundo Albuquerque, Medina, & Silva (2017) que os avanços tecnológicos e computacionais aliados ao desenvolvimento de métodos quantitativos, contribuíram para criação de diversas ferramentas de mensuração de riscos.

Além dos modelos de análise para concessão de novos créditos, conhecidos como *credit scoring*, tem crescido também o uso de outros dois tipos de modelo: i) *behavior scoring*, onde o objetivo é avaliar se clientes bancários estão aptos a terem novos créditos concedidos e; ii) *collection scoring* onde se avalia a probabilidade de pagamento a ser realizado por clientes que já estão inadimplentes e que necessitam de uma ação de cobrança (AMARAL & IQUIPAZA, 2020).

Um modelo com alto poder de classificação é muito importante, pois ajuda a instituição a direcionar suas estratégias, reduzindo custos e aumentando margens. Este artigo teve por objetivo construir um modelo de *collection scoring* para um portfólio de clientes de créditos não-performados, conhecidos como *Non-performing loans* (NPL), com o intuito de, por meio da avaliação do perfil de pagamento de cada tipo de cliente, definir as melhores estratégias de cobrança. Adicionalmente, foram propostas estratégias de cobrança a serem adotadas de acordo com o perfil de cliente

identificado na análise. Segundo Amaral & Iquipaza (2020), ainda há uma escassez de artigos que tratem sobre este tema, o que indica a importância de pesquisas nesta área.

1.1 Non-performing Loans

Segundo o Banco Central Europeu (2016), um *non-performing loans* é uma provisão para créditos inadimplentes há mais de 90 dias, pois após esse período deve-se considerar que o compromisso do tomador com a instituição não será mais honrado. No Brasil, *non-performing loans* pode ser traduzido como créditos não performados ou créditos “podres”. Um aumento no volume de créditos não performados numa instituição financeira significa no risco de insolvência desta empresa (MAKRI et al., 2014). Boumparis et.al. (2019) apontam que o principal risco que os bancos podem apresentar é o aumento de NPL, sendo que esse crescimento traz um impacto altamente negativo para a imagem do banco.

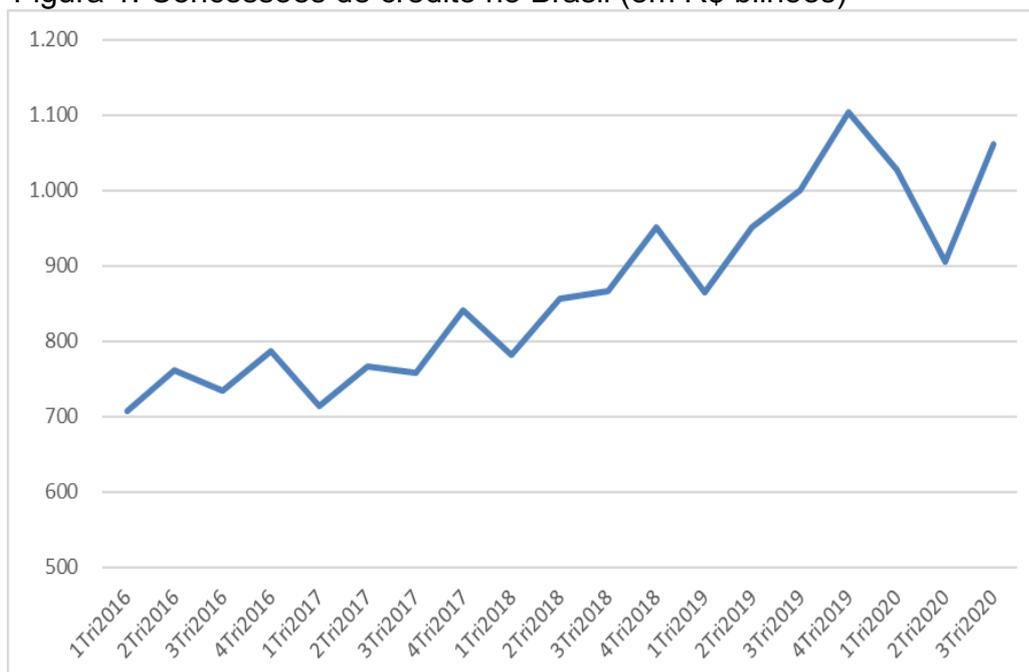
Pela classificação de Louzis et al. (2012) existem três principais razões que levam à existência de créditos não performados:

- Fatores macroeconômicos: a qualidade do crédito é afetada diretamente pelas políticas macroeconômicas vigentes no país, como: taxa praticada de juros, facilidade de acesso ao crédito, políticas fiscais, entre outras.
- Crise financeira no país: os autores apontam que em caso de o país ter uma crise de confiança internacional, como no caso da Grécia, o volume de créditos não pagos aumenta substancialmente, o mesmo sendo observado na Itália pós crise de 2007 (CAMPANELLA et al., 2020).
- Fatores específicos da instituição que cede o crédito: aqui é possível citar fatores relacionados à má gestão da instituição que cede créditos, tais como: falta de controles adequados, empréstimos cedidos sem o adequado sistema de avaliação de proponentes, entre outros.

Toledo (2013) aponta que desde meados dos anos 90, pós estabilidade alcançada pelo Plano Real a economia brasileira tem passado por um processo de crescimento alavancado pelo aumento na concessão de crédito, e, conseqüentemente, esta rápida expansão gerou uma piora na qualidade da concessão do crédito, causando aumento na inadimplência (Kauko, 2012; Makri, Tsaganos, & Bellas, 2014; Barseghyan, 2010; Lu, Thangavelu, & Hu, 2007), acarretando créditos não pagos há mais de 90 dias. O mercado de *non-performing loan* é reflexo direto do mercado de crédito local (LIU; LIU; KIM, 2020), ou seja, todo o produto de crédito comercializado por bancos, financeiras, varejistas, incorporadoras ou qualquer prestador de serviço que condicione o serviço presente a um pagamento futuro é escopo das atividades de *non-performing loan* no Brasil. Toledo (2013), aponta que entre 2002 e 2012, o volume de crédito cresceu de 25% para aproximadamente 50% do PIB. O rápido crescimento no volume do crédito pode ser considerado uma ameaça à estabilidade econômica (SAITO; FOUTO; ANGELO, 2019).

Dados do Banco Central (Banco Central do Brasil, [S.d.]) mostram o crescimento do volume de crédito concedido no Brasil no período desde o primeiro trimestre de 2016 ao terceiro trimestre de 2020, conforme Figura 1.

Figura 1: Concessões de crédito no Brasil (em R\$ bilhões)



Fonte: Banco Central do Brasil

Segundo o portal Instituto Millenium (INSTITUTO MILLENIUM, [S.d.]), no final de 2018, os bancos tiraram do seu balanço cerca de 40 bilhões de reais de créditos “podres”, quase dobrando o volume de dois anos antes (25 bilhões). O portal ainda destaca que nos últimos anos os bancos passaram a avaliar o negócio de recuperação de crédito como lucrativo e investiram mais neste segmento.

Neste cenário o destaque para a recuperação de crédito bancário, segundo Amaral & Iquipaza (2020), é de vital importância nas estratégias dos bancos, sendo que as políticas de cobrança acabam tendo um papel preponderante para a recuperação do crédito.

1.2. Políticas de Cobrança

As políticas de cobrança têm por objetivo definir os vários critérios e procedimentos possíveis de serem adotados por uma empresa, visando ao recebimento dos valores a receber (ASSAF NETO, 2014).

Segundo Becker, Seibert, Wbatuba, & Salla, (2016), a política de cobrança deve ser implementada em conjunto com a política de crédito, incorporando procedimentos para a recuperação do crédito. Não deve ser facilitada demasiadamente a concessão de crédito para, posteriormente, ser necessário aplicar rigidez na cobrança, ou vice-versa. Se já for esperada a dificuldade de cobrança no ato da concessão do crédito, a avaliação do crédito deverá ser ainda mais rigorosa (Hoji, 2014).

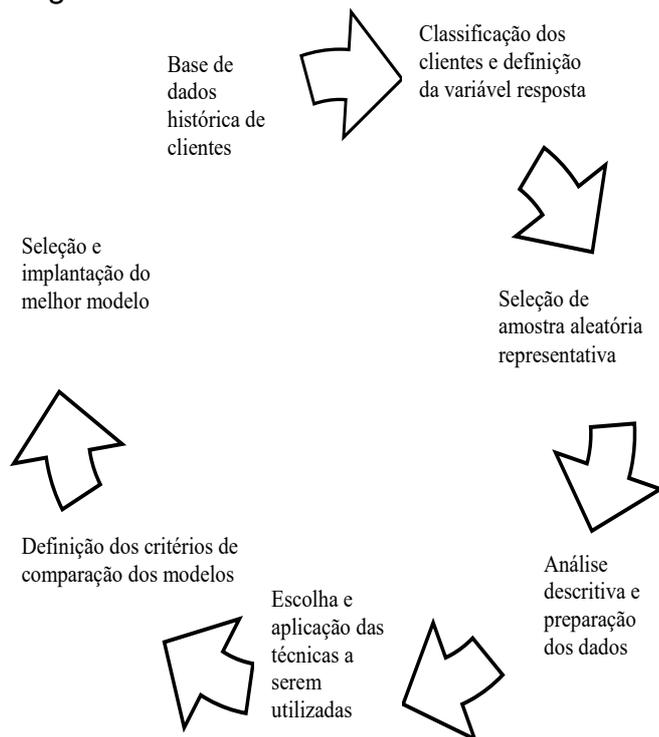
1.3. Modelos de Scoring

Segundo Crook, Edelman, & Thomas (2007), os modelos de *scoring* têm por objetivo mensurar o risco de uma carteira, durante sua vigência. De acordo com Brito & Assaf Neto (2008), o mais comum é utilizar Regressão Logística como ferramenta para construção de modelos nas quais a variável dependente é categórica e assume um entre dois resultados possíveis (binária), tais como: “normal ou anormal”, “cliente ou não cliente” e “solvente ou insolvente”; contudo, pesquisadores utilizam outras

técnicas, como: Árvores de Decisão (OLSON, DELEN, & MENG, 2012), Redes Neurais (OLSON, DELEN, & MENG, 2012; ORESKI & ORESKI, 2012), Algoritmos Genéticos (GOUVÊA, GONÇALVES, & MANTOVANI, 2012; ORESKI & ORESKI, 2012) e Análise de Sobrevivência (BELLOTTI; CROOK, 2009; HARRISON; ANSELL, 2002). Independentemente da técnica adotada, o objetivo é sempre o mesmo: classificar os clientes (ou proponentes), de acordo com o risco de inadimplência.

Gonçalves, Gouvêa e Mantovani (2013) propõem um modelo de sete passos para construção de um modelo de *credit scoring*, que pode ser utilizado para a confecção de qualquer tipo de modelo de *scoring* conforme a figura 2.

Figura 2: Ciclo de desenvolvimento de um modelo de scoring



Fonte: Gonçalves, Gouvêa & Mantovani (2013)

1. Levantamento de uma base histórica de clientes: para se construir um modelo de análise de crédito deve-se supor que os clientes têm o mesmo padrão de comportamento ao longo do tempo; partindo-se deste pressuposto, são levantadas informações passadas para construção do modelo. Nesta fase deve-se definir qual o público-alvo do modelo, quais informações serão utilizadas e qual a periodicidade dos dados a serem coletados para a construção do modelo. A qualidade dos dados e a disponibilidade dos mesmos são requisitos primordiais para o sucesso do modelo (KARR; SANIL; BANKS, 2006).

2. Classificação dos clientes de acordo com o padrão de comportamento e definição da variável resposta: Nesta fase são definidos quais são os grupos de clientes a serem modelados. Em geral, trabalha-se com dois tipos de classificação de clientes, chamados de bons clientes e maus clientes. Importante ressaltar que cada instituição tem sua própria política e os conceitos de bons e maus podem ter variações, de acordo com a instituição, e mesmo mudar ao longo do tempo dentro da instituição. Em geral, além de clientes bons e maus, podem existir, também, clientes excluídos (indivíduos que possuem características peculiares e não devem ser

considerados; por exemplo, clientes que trabalham na instituição) e os clientes indeterminados (aqueles que ficam na chamada “zona cinzenta” e não podem ser classificados ainda como bons ou maus; por exemplo, clientes novos). Na prática de mercado, as instituições preferem trabalhar apenas com clientes bons e maus para o desenvolvimento do modelo em virtude da maior facilidade de se trabalhar com modelos de resposta binária. Nos trabalhos acadêmicos também a tendência é trabalhar apenas com clientes bons e maus (GONÇALVES, GOUVÊA & MANTOVANI, 2013; OLSON, DELEN, & MENG, 2012; ORESKI, ORESKI, & ORESKI, 2012; SILVA, 2011).

3. Seleção de amostra aleatória representativa da base histórica: após ter a base selecionada e a variável resposta definida, o passo seguinte é selecionar amostras representativas de cada grupo de cliente definido (2 grupos em caso de desenvolvimento do modelo para clientes bons e maus). Para se evitar qualquer tipo de viés em virtude de tamanho, é importante que a amostragem seja estratificada de forma igualitária nos grupos definidos (CROOK; EDELMAN; THOMAS, 2007). O número de clientes a serem amostrados depende de vários fatores, como tamanho da população e facilidade de acesso aos dados, homogeneidade da população entre outros; entretanto, Lewis (1992) propõe que com uma amostra de 1.500 clientes para cada tipo de resposta já é possível obter resultados robustos. Normalmente os estudos trabalham com duas amostras, a primeira para construção do modelo e a segunda para validação e teste do modelo.

4. Análise descritiva e preparação dos dados: nesta fase é analisada, com critérios estatísticos, cada variável a ser utilizada no modelo.

5. Escolha e aplicação das técnicas a serem utilizadas para a construção do modelo: neste trabalho será utilizada Regressão Logística, selecionada dentre outras técnicas que também podem ser utilizadas para construção de modelos, algumas com maior ou menor complexidade. Gonçalves (2005) fez um levantamento bibliográfico sobre modelos de *scoring* e identificou as seguintes técnicas sendo utilizadas em tais modelos: Regressão Linear, Regressão Logística, Árvores de Classificação, Programação Linear, Algoritmos Genéticos, Redes Neurais, Análise Discriminante e Real. O levantamento também concluiu que os resultados de pesquisas acadêmicas divergem em relação à qual seria a melhor técnica, atestando que não existe uma técnica que se revele sempre superior às demais, uma vez que, dependendo dos dados a serem modelados, uma técnica pode prevalecer em relação às demais.

6. Definição dos critérios de comparação dos modelos: neste passo são definidas as medidas de comparação dos modelos; as ferramentas mais comumente utilizadas são o índice de Gini, a curva ROC, a estatística de Kolmogorov-Smirnov (KS) e a taxa de acertos.

7. Seleção e implantação do melhor modelo: uma vez escolhido o melhor modelo, pelos critérios de comparação estabelecidos no tópico anterior, chega-se ao momento de implantação do modelo. Todas as áreas envolvidas devem se reunir para definição do plano de implantação: prazos, fases e impactos esperados devem estar claros para todos os envolvidos para não haver surpresas ao longo do processo (OLSON, DELEN, & MENG, 2012).

1.4 Modelos de Collection Scoring

O modelo de *collection scoring* tem por finalidade identificar a probabilidade de pagamento dos clientes que já se tomaram inadimplentes. Isso significa que a população alvo do modelo de cobrança é aquela formada por clientes que não cumpriram com as suas obrigações de pagamentos nos prazos combinados com as

instituições credoras (SOUZA, 2000). Este tipo de modelo é uma ferramenta que permite prever as perdas a partir da probabilidade de pagamento de clientes já inadimplentes, visando aprimorar o processo de cobrança, a fim de maximizar a recuperação, reduzir custos e automatizar fluxos (MACHADO, 2015). Os clientes com diferentes graus de insolvências são alocados em grupos, separando-se aqueles que necessitam de maior ação de cobrança daqueles que não necessitam ser cobrados de forma imediata (SADATRASOUL, et al., 2013).

De acordo com Machado (2015), as principais variáveis deste modelo são:

- Informações demográficas como: idade, endereço entre outras e informações obtidas em bureaux de crédito (protestos, cheques sem fundo, pendências e restrições financeiras) e;
- Relacionamento do cliente com a empresa: atraso no pagamento em meses anteriores, tempo de relacionamento com a empresa, gasto do cliente com a empresa em transações anteriores, contatos anteriores com o cliente, entre outras.

2. Metodologia

Apresentam-se a seguir algumas informações sobre o desenvolvimento do trabalho, a seleção da amostra estratificada, a aplicação da regressão logística e o uso da estatística de Kolmogorov-Smirnov; foi utilizado o software SPSS for Windows v.21.

2.1 Dados

Uma empresa especializada em cobrança de portfólio do tipo *non-performing loan* cedeu uma amostra de 254.914 clientes pessoa física, proveniente de uma carteira que foi trabalhada em maio de 2017, durante um período de seis meses, só fazendo parte da amostra clientes com que a empresa efetivamente fez contato. Os clientes com os quais não foi conseguido o contato não fazem parte da amostra pela impossibilidade de classificá-los como bons ou maus.

Este tipo de empresa compra carteira de uma instituição (financeira ou não) por um preço menor do que o valor da dívida (no caso deste estudo o preço médio é 5% do valor da dívida). Em geral, a carteira vendida foi exaustivamente trabalhada pelo departamento de cobrança da instituição que a vende por não ter perspectiva, interesse ou expertise para continuar cobrando.

2.2 Definição da Variável Resposta

A variável resposta definida será baseada no pagamento (ou não) efetuado pelo cliente. Clientes denominados bons são aqueles que aceitaram o acordo com a empresa de cobrança e o honraram pagando ao menos uma parcela do valor combinado. Os chamados clientes maus são definidos como aqueles que não aceitaram nenhum tipo de acordo ou aceitaram, mas quebraram a promessa não pagando parcela alguma para a empresa de cobrança.

2.3 Amostra

Foram selecionadas duas amostras: uma para a construção e outra para a validação do modelo. Conforme mencionado no passo 3 do ciclo de desenvolvimento do modelo, na amostra para construção do modelo, os números de clientes bons e maus devem ser de igual tamanho (amostra estratificada igualitária); desta forma, foram selecionados 90.000 clientes estratificados pela variável resposta, sendo

45.000 classificados como Bons e 45.000 classificados como “Maus”; os demais clientes ficaram na amostra de validação e teste do modelo.

2.4. Variáveis Independentes

As variáveis cadastrais disponíveis do cliente, bem como as variáveis de comportamento observadas foram utilizadas para a construção do modelo, sendo apresentadas como Variáveis Demográficas e de Relacionamento. Sendo assim, tem-se:

Variáveis Demográficas:

- Idade do Cliente;
- Região de residência (Norte, Nordeste, Centro-Oeste, Sudeste e Sul);
- Quantidade de telefones residenciais no cadastro;
- Quantidade de telefones comerciais no cadastro;
- Quantidade de e-mails no cadastro;
- Presença de restritivos em bureau externo de crédito (protestos, cheques sem fundo, Refin ou Pefin);
- Escore calculado pelo bureau externo de crédito.

Variáveis de Relacionamento:

- Valor da dívida;
- Dias em atraso;
- Quantidade de contatos anteriores por telefone;
- Quantidade de contatos anteriores por e-mail;
- Quantidade de vezes que este cliente já apareceu em uma carteira cobrada por esta empresa.

Estas variáveis são comumente usadas neste tipo de modelo, conforme pode ser visto em trabalhos similares (AMARAL; IQUIAPAZA, 2020; FORTI, 2018; KHIEU; MULLINEAUX; YI, 2012; SOUZA, 2000).

Todas as variáveis foram categorizadas em faixas, transformando-se em variáveis ordinais. Essa técnica é largamente utilizada em problemas deste tipo, uma vez que visa diminuir o efeito de outliers e tornar as estimativas mais robustas (FORTI, 2018; GONÇALVES; GOUVÊA; MANTOVANI, 2013)

2.5 Regressão Logística

A Regressão Logística, como já mencionado, é a técnica mais largamente utilizada para este tipo de problema; baseia-se no cálculo da probabilidade de o cliente ser classificado em cada um dos grupos (HAIR et al., 2010). Tomando por base a categoria dos clientes classificados como “Bons”, a probabilidade de um cliente qualquer ser classificado como “bom” será dada por:

$$p(x) = \frac{\exp(\beta'X)}{1 + \exp(\beta'X)}$$

onde $\beta' = (\beta_0, \beta_1, \beta_2, \dots, \beta_n)$ é vetor de parâmetros associados às variáveis independentes (Demográficas e de Relacionamento).

2.6 Critérios para avaliação de performance

O primeiro critério para avaliar performance utilizado foi a seleção de uma amostra de validação; se os resultados da amostra de validação forem próximos aos da amostra de desenvolvimento significa que o modelo estará apto para ser utilizado em outras bases. Outros dois critérios serão utilizados para avaliar a performance do modelo: Taxa de acertos e Teste de Kolmogorov-Smirnov (HAIR et al, 2010).

2.7 Taxa de Acertos

Segundo Gonçalves, Gouvêa, & Mantovani (2013), a taxa de acerto se mede por meio da divisão do total de clientes classificados corretamente, pela quantidade de clientes que fizeram parte do modelo. O mesmo cálculo pode ser feito para cada grupo de cliente analisado de acordo com o modelo (“Bom” e “Mau” pagador).

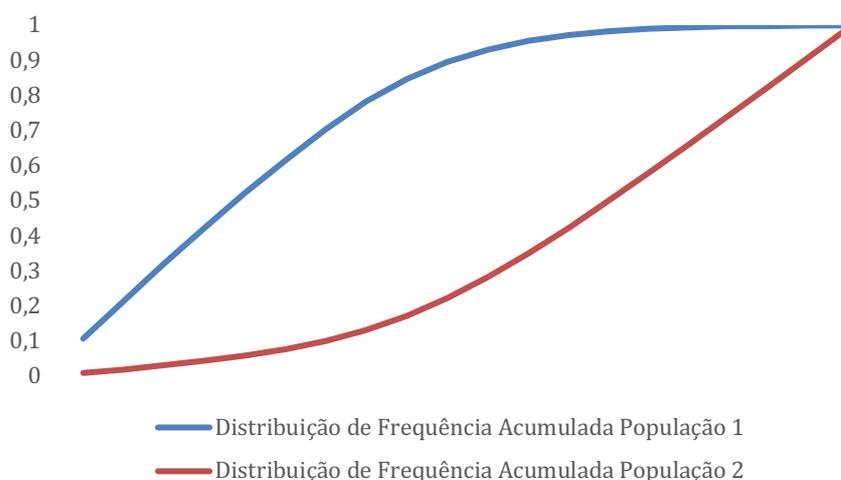
Além da taxa de acertos, os autores propõem a adoção de um indicador chamado de índice de acertos (I_a) obtido pelo produto da taxa de acertos dos clientes classificados como “bons” pela taxa de acertos dos clientes classificados como “maus”, esse indicador é importante para aferir se o modelo está classificando bem os clientes independentemente de classificá-los como “bom” ou “mau”.

2.7 Teste de Kolmogorov-Smirnov

O teste de Kolmogorov-Smirnov (KS) é uma técnica estatística não paramétrica que visa determinar se duas amostras são oriundas da mesma população (SIEGEL; CASTELLAN JR, 2006); no caso do presente trabalho, busca-se diferenciar os clientes bons dos clientes classificados como maus. Para aplicar este teste, é construída uma distribuição de frequência cumulativa para cada amostra de observações, utilizando-se os mesmos intervalos para ambas as distribuições. Para cada intervalo é subtraída uma função da outra. O teste foca o maior desvio observado. A Figura 3 exemplifica o emprego do teste de KS.

Segundo Crook, Edelman & Thomas (2007), esta é uma importante medida de separação; quanto maior o KS obtido no modelo, melhor o modelo consegue diferenciar os clientes maus dos clientes bons.

Figura 3: Exemplo de um teste de KS



Fonte: Adaptado de Crook, Edelman, & Thomas (2007)

3. Resultados e Discussão

3.1. Regressão Logística

Neste trabalho, inicialmente, todas as variáveis foram incluídas para a construção do modelo; entretanto, no modelo logístico final, apenas algumas variáveis foram selecionadas. A escolha das variáveis foi feita por intermédio do método *forward stepwise*, que é o método mais largamente utilizado em modelos de regressão logística (Gonçalves et al., 2013). No método *forward stepwise* as variáveis entram e saem do modelo a cada passo, de forma que o modelo seja otimizado, evitando-se multicolinearidade e reduzindo-se a variância interna dos grupos.

O modelo resultante inicialmente era composto de 29 variáveis, sendo que as mais importantes para classificação do cliente foram o tempo de atraso da dívida, a classificação do bureau de crédito externo e se o cliente anteriormente teve algum contato por e-mail, conforme aponta a Tabela 1.

Tabela 1: Variáveis do modelo

Variável	Coefficiente logístico estimado (B)	Teste de Wald	Nível de Significância	Exp (B)
Atraso até 360 dias	1,833	99,210	0,000	6,255
Atraso de 361 a 720 dias	0,659	267,340	0,000	1,933
Atraso de 721 a 1080	0,068	4,342	0,037	1,071
Atraso de 1441 a 1800	- 0,213	31,447	0,000	0,808
Atraso maior de 1800	-2,162	2105,431	0,000	0,115
Teve contato anterior por telefone	0,189	59,307	0,000	1,208
Possui e-mail de contato	1,327	3236,108	0,000	3,771
Apareceu mais de 1 vez na carteira	- 0,271	57,587	0,000	0,763
Nunca apareceu na carteira	0,343	87,221	0,000	1,409
Saldo até R\$ 500,00	0,150	19,021	0,000	1,162
Saldo de R\$ 1001 a R\$ 5000	- 0,214	68,014	0,000	0,807
Saldo > R\$ 5000	- 0,952	787,678	0,000	0,386
Idade de 18 a 40	0,189	62,159	0,000	1,208
Idade maior que 50	- 0,143	20,239	0,000	0,866
Presença de Restritivos em bureau	- 0,497	284,601	0,000	0,609
Possui 2 ou mais credores	- 0,511	580,563	0,000	0,600
Já houve contato via e-mail	1,363	1874,063	0,000	3,909
Região de contato	0,209	36,770	0,000	1,233
Sem escore de bureau externo	2,870	6844,671	0,000	17,642
Escore de bureau externo faixa1	- 0,411	65,871	0,000	0,663
Escore de bureau externo faixa3	0,362	90,257	0,000	1,436
Escore de bureau externo faixa 4	0,816	478,619	0,000	2,263
Escore de bureau externo faixa 5	1,558	1699,357	0,000	4,749
Não declarou telefone	- 0,248	82,511	0,000	0,781
Declarou dois ou mais telefones	0,215	95,250	0,000	1,240
Não declarou telefone comercial	- 0,507	147,924	0,000	0,602
Declarou dois ou mais telefones comercial	0,357	7,094	0,008	1,429
Não declarou telefone residencial	- 0,122	25,312	0,000	0,885
Declarou dois ou mais telefones residenciais	0,250	99,158	0,000	1,284
Constante	- 1,232	325,232	0,000	0,292

O teste de Omnibus mede se o modelo é capaz de realizar as previsões com a precisão desejada (Gonçalves et al., 2013). A Tabela 2 a seguir mostra que o teste de significância corrobora que o modelo é capaz de fazer previsões adequadamente (sig < 0,05).

Tabela 2: Testes de coeficientes de modelo Omnibus

	Qui-quadrado	Df	Significância.
Etapa	4,342	1	0,037
Bloco	56013,551	29	0,000
Modelo	56013,551	29	0,000

Em seguida, foi feito o teste da taxa de acertos do modelo. A Tabela 3 mostra que a taxa de acertos deste modelo é de 83,9% na amostra de desenvolvimento e 83,4% na amostra de validação. Importante notar que os percentuais de acerto para “bons” e “maus” estão próximos entre si e não há mudança quando se passa da amostra de desenvolvimento para a amostra de validação; o que denota um bom resultado para o modelo. De acordo com Selau & Ribeiro (2011), modelos com taxa de acerto superior a 65% são considerados adequados por especialistas.

O índice de acertos do modelo foi de 70,4 para a amostra de desenvolvimento e 70,3 para a amostra de validação, superior inclusive ao obtido por Gonçalves, Gouvêa, & Mantovani (2013) no artigo onde foi proposta a adoção do indicador (foi obtido 51,3 para a amostra de desenvolvimento e 48,2 para validação).

Tabela 3: Taxas de acertos

Amostra			Predito		% acerto
			Mau	Bom	
Desenvolvimento	Observado	Mau	38.495	6.505	85,5%
		Bom	7.968	37.032	82,3%
	Total	46.463	43.537	83,9%	
Validação	Observado	Mau	51.317	8.721	85,5%
		Bom	18.712	86.164	82,2%
	Total	70.029	94.885	83,4%	

O resultado do teste KS obtido para o conjunto de desenvolvimento foi de 68,0, enquanto na amostra de validação chegou em 67,9 indicando, da mesma forma que a taxa de acertos, que os resultados das amostras de desenvolvimento são bons e muito próximos. Como referência, Souza (2000) aponta que acima de 40, um modelo de *collection scoring* apresenta um bom índice de separação.

3.2 Aplicação dos resultados na estratégia de cobrança

Uma vez construída a ferramenta de avaliação de propensão ao pagamento, cabe ao analista adequar o resultado do modelo às estratégias de cobrança existentes na empresa. Nesta seção são apresentadas alternativas para essa adequação.

Para a proposta de atuação foi utilizada toda a carteira (abrangendo as amostras de desenvolvimento e validação), onde cada cliente recebeu uma pontuação (*score*) determinada pelo modelo logístico. Os clientes são separados em vinte faixas de igual tamanho (cada uma com 5% da população), de acordo com sua pontuação, o modelo é dividido em vinte faixas. Em cada uma destas faixas os clientes são marcados como “bons” ou “maus” pagadores. Caso o modelo esteja bem ajustado, a maior concentração de clientes maus estará nas menores faixas, ao passo que os

clientes chamados bons devem se situar com maior frequência nas faixas mais altas. A Tabela 4 a seguir mostra a distribuição nas vinte faixas.

Tabela 4: Distribuição de Clientes Bons e Maus de acordo com a faixa de escore

Faixa de Escore	Qte de Bons	Qte de Maus	Total na faixa	% de Bons na Faixa
Faixa 1	1.439	11.307	12.746	11,3%
Faixa 2	1.483	11.231	12.714	11,7%
Faixa 3	1.724	11.136	12.860	13,4%
Faixa 4	1.957	10.710	12.667	15,4%
Faixa 5	2.234	10.507	12.741	17,5%
Faixa 6	2.853	9.902	12.755	22,4%
Faixa 7	3.458	9.348	12.806	27,0%
Faixa 8	4.599	8.076	12.675	36,3%
Faixa 9	5.957	6.788	12.745	46,7%
Faixa 10	7.697	5.055	12.752	60,4%
Faixa 11	9.092	3.650	12.742	71,4%
Faixa 12	10.059	2.688	12.747	78,9%
Faixa 13	10.993	1.772	12.765	86,1%
Faixa 14	11.590	1.137	12.727	91,1%
Faixa 15	11.988	756	12.744	94,1%
Faixa 16	12.309	441	12.750	96,5%
Faixa 17	12.452	289	12.741	97,7%
Faixa 18	12.542	154	12.696	98,8%
Faixa 19	12.658	65	12.723	99,5%
Faixa 20	12.792	26	12.818	99,8%

O modelo de *collection scoring* desenvolvido conseguiu uma boa separação, visto que o percentual de clientes bons cresce a cada faixa. Certamente clientes pontuados entre as faixas 14 e 20, cuja probabilidade de pagamento é superior a 90%, podem ser abordados com técnicas de cobrança mais flexíveis, por exemplo oferecendo menos descontos na negociação; de forma inversa, os clientes das faixas 1 a 5, cuja probabilidade de aceitar um acordo é inferior a 20%, necessitam de uma abordagem mais agressiva, com descontos maiores e mais tempo dedicado à negociação para potencializar a possibilidade maior de recebimento.

4. Conclusão

O aumento no volume de concessões de créditos pós plano Real leva a um crescimento da carteira de *non-performing loans*, e este tipo de ativo passou a chamar mais a atenção no Brasil. O objetivo deste estudo foi adequar um modelo de *collection scoring*, utilizando regressão logística, a um portfólio de clientes do tipo *non-performing loans*, cujos resultados se mostraram adequados. Foram tomados os cuidados na amostragem, tratamento das variáveis e critérios de avaliação dos clientes para desenvolver um modelo robusto.

Os resultados obtidos, conforme sintetizados na tabela 5, mostram a qualidade do modelo na comparação com os parâmetros de comparação apontado por outros autores.

Tabela 5: Resultados do Modelo

	Taxa de acertos (%)	KS	la
Amostra de Desenvolvimento	83,9	68,0	70,4
Amostra de Validação	83,4	67,9	70,3
Referência de Qualidade pesquisada na literatura	Superior a 65	Superior a 40	Superior a 51,3

Na literatura pesquisada foram encontrados poucos artigos que falam especificamente sobre *collection scoring* e clientes do tipo *non-performing loans*. Essa pesquisa contribui para enriquecer o conhecimento científico sobre esse tema tão pouco explorado. Ainda procura mostrar uma proposta de adequar o modelo apresentado às estratégias de cobrança.

Estudos futuros poderão focar em outras técnicas para desenvolvimento de modelos para este tipo de portfólio, como, por exemplo, redes neurais ou algoritmos genéticos; outra oportunidade para aprofundar o estudo é entender mais amplamente a palheta de ofertas da empresa e construir uma projeção de rentabilidade de acordo com as políticas existentes, sugerindo talvez mudanças nos percentuais de descontos trabalhados de forma a maximizar resultados da empresa.

Referências

ALBUQUERQUE, P. H. M.; MEDINA, F. A. S.; SILVA, A. R. DA. Geographically Weighted Logistic Regression Applied to Credit Scoring Models. *Revista Contabilidade & Finanças*, v. 28, n. 73, p. 93–112, 1 abr. 2017. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1519-70772017000100093&lng=en&tlng=en>. Acesso em: 8 out. 2019.

AMARAL, G. H. DE O.; IQUIAPAZA, R. A. Determinantes de Inadimplência e de Recuperação de Crédito em um Banco de Desenvolvimento. *BASE – Revista de Administração e Contabilidade da Unisinos*, v. 17, n. 3, p. 483–519, 2020.

ASSAF NETO, A. *Curso de Administração Financeira*. São Paulo: Atlas, 2014. BANCO CENTRAL DO BRASIL. Disponível em: <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>>. Acesso em: 1 dez. 2020.

BANCO CENTRAL EUROPEU. What are non-performing loans? Disponível em: <<https://www.ecb.europa.eu/explainers/tell-me/html/npl.en.html>>. Acesso em: 14 ago. 2019.

BARSEGHYAN, L. Non-performing loans , prospective bailouts , and Japan ' s slowdown. *Journal of Monetary Economics*, v. 57, n. 7, p. 873–890, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jmoneco.2010.08.002>>.

BECKER, G. P. et al. A Inadimplência Empresarial em Instituições Bancárias: um Estudo de Caso em Cobrança Terceirizada. *Pensar Contábil*, v. 18, n. 66, 2016.

BELLOTTI, T.; CROOK, J. Credit scoring with macroeconomic variables using survival analysis. *Journal of the Operational Research Society*, v. 60, n. 12, p. 1699–1707, 21

dez. 2009. Disponível em: <<https://www.tandfonline.com/doi/full/10.1057/jors.2008.130>>. Acesso em: 14 ago. 2019.

BOUMPARIS, P.; MILAS, C.; PANAGIOTIDIS, T. Non-performing loans and sovereign credit ratings. *International Review of Financial Analysis*, v. 64, n. May, p. 301–314, 2019. Disponível em: <<https://doi.org/10.1016/j.irfa.2019.06.002>>.

BRITO, G. A. S.; ASSAF NETO, A. Modelo de classificação de risco de crédito de empresas. *Revista Contabilidade & Finanças*, v. 19, n. 46, p. 18–29, 1 abr. 2008. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1519-70772008000100003&lng=pt&tlng=pt>. Acesso em: 8 out. 2019.

CAMPANELLA, F. et al. The effects of the credit selection criteria on non-performing loans Evidence on small and large banks in Italy. *Meditari Accountancy Research*, v. 28, n. 2, p. 251–275, 2020.

CROOK, J. N.; EDELMAN, D. B.; THOMAS, L. C. Recent developments in consumer credit risk assessment. *European Journal of Operational Research*, v. 183, n. 3, p. 1447–1465, dez. 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0377221706011866>>. Acesso em: 23 maio 2014.

FERREIRA, M. A. M.; CELSO, A. S. D. S.; BARBOSA NETO, J. E. Aplicação Do Modelo Logit Binominal Na Análise Do Risco De Crédito Em Instituições Bancárias. *Revista de Negócios*, v. 17, n. 1, p. 38, 2012.

FONSECA, S. E. et al. Análise do Impacto de Variáveis Macroeconômicas no Desempenho Financeiro e Endividamento de Empresas Listadas na B3. *Revista Universo Contábil*, v. 14, n. 4, p. 93–114, 2019.

FORTI, M. Técnicas de Machine Learning aplicadas na recuperação de crédito do mercado brasileiro. 2018. 74 f. Fundação Getulio Vargas, 2018.

GONÇALVES, E. B. Análise de risco de crédito com o uso de modelos de regressão logística, redes neurais e algoritmos genéticos. 2005. Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo, São Paulo, 2005. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/12/12139/tde-09042008-144032/>>. Acesso em: 8 out. 2019.

GONÇALVES, E. B.; GOUVÊA, M. A.; MANTOVANI, D. M. N. Análise de risco de crédito com o uso de regressão logística. *Revista Contemporânea de Contabilidade*, v. 10, n. 20, p. 139–160, 2013.

GOUVÊA, M. A.; GONÇALVES, E. B.; MANTOVANI, D. M. N. Aplicação De Regressão Logística E Algoritmos Genéticos Na Análise De Risco De Crédito. *Revista Universo Contábil*, p. 84–102, 30 abr. 2012. Disponível em: <<http://proxy.furb.br/ojs/index.php/universocontabil/article/view/2374/1946>>. Acesso em: 30 jun. 2014.

HAIR, J. F. et al. *Multivariate Data Analysis*. 7th. ed. New York City: [s.n.], 2010.

HARRISON, T.; ANSELL, J. Customer retention in the insurance industry: Using survival analysis to predict cross-selling opportunities. *Journal of Financial Services Marketing*, v. 6, n. 3, p. 229–239, 1 mar. 2002. Disponível em: <<http://link.springer.com/10.1057/palgrave.fsm.4770054>>. Acesso em: 14 ago. 2019.

HOJI, M. *Administração Financeira e Orçamentária*. 2. ed. São Paulo: Atlas, 2014.

INSTITUTO MILLENIUM. Bancos devem negociar até R\$ 40 bilhões em créditos podres este ano - Instituto Millenium. Disponível em: <<https://www.institutomillennium.org.br/blog/bancos-devem-negociar-ate-r-40-bilhoes-em-creditos-podres-este-ano/>>. Acesso em: 15 ago. 2019.

KARR, A. F.; SANIL, A. P.; BANKS, D. L. Data quality: A statistical perspective. *Statistical Methodology*, v. 3, n. 2, p. 137–173, 1 abr. 2006. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1572312705000638>>. Acesso em: 14 ago. 2019.

KAUKO, K. External deficits and non-performing loans in the recent financial crisis. *Economics Letters*, v. 115, n. 2, p. 196–199, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.econlet.2011.12.018>>.

KHIEU, H. D.; MULLINEAUX, D. J.; YI, H. C. The determinants of bank loan recovery rates. *Journal of Banking and Finance*, v. 36, n. 4, p. 923–933, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jbankfin.2011.10.005>>.

LEWIS, E. M. *An Introduction to Credit Scoring*. San Rafael: [s.n.], 1992.

LIU, L.; LIU, Y.; KIM, J. M. Sustainable visual analysis for bank non-performing loans and government debt distress. *Sustainability (Switzerland)*, v. 12, n. 1, 2020.

LOUZIS, D. P.; VOULDIS, A. T.; METAXAS, V. L. Macroeconomic and bank-specific determinants of non-performing loans in Greece : A comparative study of mortgage , business and consumer loan portfolios. *Journal of Banking and Finance*, v. 36, n. 4, p. 1012–1027, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jbankfin.2011.10.012>>.

LU, D.; THANGAVELU, S. M.; HU, Q. The Journal of Development Biased Lending and Non- performing Loans in China ' s Banking Sector. n. May 2014, p. 37–41, 2007.

MACHADO, A. R. *Collection Scoring via Regressão Logística e Modelo de Riscos Proporcionais de Cox*. 2015. 105 f. Universidade de Brasília, 2015.

MAKRI, V. et al. *Determinants of Non-Performing Loans : The Case of Eurozone*.

PANOECONOMICUS, v. 77, n. April 2013, p. 193–206, 2014.

OLSON, D. L.; DELEN, D.; MENG, Y. Comparative analysis of data mining methods for bankruptcy prediction. *Decision Support Systems*, v. 52, n. 2, p. 464–473, jan. 2012.

Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0167923611001709>>. Acesso em: 5 jun. 2014.

ORESKI, S.; ORESKI, D.; ORESKI, G. Hybrid system with genetic algorithm and artificial neural networks and its application to retail credit risk assessment. *Expert Systems with Applications*, v. 39, n. 16, p. 12605–12617, nov. 2012. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S095741741200721X>>. Acesso em: 29 maio 2014.

SADATRASOUL, S. M. et al. Credit scoring in banks and financial institutions via data mining techniques : A literature review. v. 1, n. 2, p. 119–129, 2013.

SAITO, A. T.; FOUTO, N. M. M. D.; ANGELO, C. F. DE. BRICS: Liquidez, Consumo e Relevância de Políticas de Produtividade e de Comércio Internacional para o IED. *Revista Universo Contábil*, v. 15, n. 3, p. 07–26, 2019.

SELAU, L. P. R.; RIBEIRO, J. L. A Systematic Approach To Construct Credit Risk Forecast Models. *Brazilian Operations Research Society*, v. 31, n. 1, p. 41–56, 2011. SIEGEL, S.; CASTELLAN JR, N. J. *Estatística não-Paramétrica Para Ciências do Comportamento*. 2. ed. Porto Alegre: Bookman, 2006.

SILVA, P. R. *Psicologia do risco de crédito: análise da contribuição de variáveis psicológicas em modelos de credit scoring*. 2011. Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo, São Paulo, 2011. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/12/12139/tde-30092011-184818/>>. Acesso em: 15 ago. 2019.

SOUZA, R. B. DE. *O modelo de collection scoring como ferramenta para a gestão estratégica do risco de crédito*. 2000. 2000. Disponível em: <<https://bibliotecadigital.fgv.br/dspace/handle/10438/5723>>. Acesso em: 14 ago. 2019.

TOLEDO, R. P. P. DE. *Mercado brasileiro de non-performing loans (NPL): uma abordagem teórica e prática na precificação de ativos*. 2013. 2013. Disponível em: <<https://bibliotecadigital.fgv.br/dspace/handle/10438/10601>>. Acesso em: 14 ago. 2019.