

ANÁLISE DE CREDIT SCORING UTILIZANDO REDES NEURAIAS

Pedro Rehfeld Schoen

pedroschoe@gmail.com

Flávio Sanson Fogliatto

fogliatto@producao.ufrgs.br

Resumo

Bancos e instituições financeiras usualmente desejam saber quais clientes pagarão o crédito concedido. Para tanto, usam modelos estatísticos de *credit scoring*. Nos últimos anos, redes neurais se estabeleceram como uma das ferramentas com melhores resultados em desenvolvimento de modelos de *credit scoring*. A fim de aprimorar a precisão de modelos de *credit scoring*, esse artigo tem como objetivo analisar o uso de variáveis *dummy* e seleção *stepwise* de variáveis no desenvolvimento de modelos de *credit scoring* com redes neurais. Para isso, foram desenvolvidos a partir de uma base de dados de um banco de Taiwan, 4 modelos, com variações de uso/não uso de variáveis *dummy* e seleção *stepwise*. Comparando-os, constatou-se que ambos os modelos com uso de variáveis *dummy*, com ou sem uso de seleção *stepwise*, tiveram resultados melhores comparados à base padrão. Também se verificou que a seleção *stepwise* traz um ganho pequeno se considerado o aumento do tempo necessário para sua aplicação.

Palavras-chave: *credit scoring*, redes neurais, variáveis *dummy*, seleção *stepwise*.

1. INTRODUÇÃO

Atualmente, cada vez mais se vê necessidade por parte de bancos e instituições financeiras de saber quem serão os clientes que devolverão o crédito concedido. A decisão de aceitar ou não a tentativa de crédito de um cliente é feita usando conhecimentos tácitos ou modelos de *credit scoring*. Devido a sua assertividade, com o passar dos anos os modelos de *credit scoring* tornaram-se uma das mais importantes ferramentas para avaliar o risco de empréstimos (ABDOU et al., 2008). Modelos de *credit scoring* dizem se o cliente tentando crédito é “bom”, ou seja, se vai pagar o que deve, ou se é “mau”, significando que não vai honrar com sua dívida.

Modelos de *credit scoring*, na sua essência, mostram qual o risco de se emprestar o dinheiro baseado em características quantitativas dos clientes analisados (DINH;

KLEIMEIER, 2007). O objetivo central é usar informações financeiras, como históricos de transação e pagamentos, para prever o risco de crédito de consumidores ou negócios e com isso reduzir a perda e a incerteza (YEH; LIEN, 2009). Não há um consenso sobre qual é o melhor método para obter os modelos. Regressão linear e análise discriminante são as técnicas mais usadas. Outras técnicas incluem regressão logística, análise *probit*, programação matemática, cadeias de Markov, algoritmos genéticos e redes neurais (HAND; HENLEY, 1998).

Redes neurais, em particular, vêm sendo cada vez mais usadas para desenvolvimento de modelos de *credit scoring*. Redes neurais podem ser definidas como modelos computacionais baseados no cérebro humano, sendo seu elemento principal os *neurons*, que são interligados por meio de conexões que são associadas com pesos, os quais guardam o conhecimento da rede neural quando ela é treinada (BRAGA *et al.*, 2007). Abdou *et al.* (2008) fizeram a comparação entre redes neurais e regressões logísticas, análises discriminantes e análises *probit* no mercado financeiro egípcio e constataram resultados superiores das redes neurais. Yeh e Lien (2009) realizaram um estudo comparativo entre redes neurais, algoritmo *k-nearest neighbor*, regressão logística, análise discriminante, classificador de NaiveBayes e árvores de decisão, usando dados de cartões de crédito obtidos no mercado financeiro de Taiwan. Apesar de todos os métodos terem um nível de erro similar, as redes neurais tiveram maior acurácia.

Outras técnicas podem ser aplicadas em conjunto com as redes neurais para um melhor resultado do modelo. É possível fazer uso de variáveis *dummy*, que são variáveis que assumem valores de 0 a 1. Variáveis *dummy* são usadas para transformar variáveis categóricas em diversas variáveis binárias mutuamente exclusivas. O seu uso faz com que estudos sejam de mais fácil aplicação, uso e interpretação, além de aumentar a estabilidade e significância dos coeficientes (GARAVAGLIA; SHARMA, 1998). Em *credit scoring*, para fazer o agrupamento de variáveis independentes em variáveis *dummy*, se calcula o risco relativo, que é um indicador baseado na razão do percentual de clientes “bons” e “maus”, e indica quanto um atributo separa uma variável (SELAU, 2008).

O método *stepwise* de seleção de variáveis, usado principalmente em análises de regressão, também pode ser aplicado a redes neurais. Trata-se de um método para eliminar variáveis a fim de diminuir o erro de previsão do modelo. Ele pode ser implementado de forma *forward*, onde o modelo inicial não apresenta nenhuma variável e a inclusão destas é testada uma a uma, com vistas a minimizar o erro de previsão do modelo, ou de forma *backward*, onde o modelo inicial é aquele que contempla todas as variáveis, as quais vão

sendo eliminadas uma a uma em busca do modelo com menor erro de previsão (RENCHEER, 2003).

Nesse contexto, os objetivos do presente estudo são (1) desenvolver um modelo de credit scoring a partir de redes neurais, (2) medir o impacto da separação das variáveis independentes em variáveis *dummy* através do risco relativo no resultado da rede neural, e (3) analisar se o método *stepwise* melhora o desempenho preditivo dos modelos de redes neurais. Devido à confidencialidade dos dados, bancos não liberam informações de seus clientes. Em razão disso, a base de dados trabalhada nesse estudo é uma base pública de clientes de um banco de Taiwan, contemplando clientes que pediram crédito em Outubro de 2005.

O restante do artigo está organizado da seguinte maneira. A segunda seção apresenta uma revisão teórica, sendo feita com base na literatura existente sobre o assunto. A terceira seção apresenta como será desenvolvido o modelo de *credit scoring*. A quarta sessão apresenta os resultados do estudo. Por fim, na última seção serão apresentadas as conclusões geradas por esse estudo.

2.REFERENCIAL TEÓRICO

Com uso de modelos de *credit scoring*, instituições financeiras podem potencializar lucros, além de terem o benefício de uma avaliação de crédito rápida e padronizada, evitando o uso de critérios subjetivos por parte de analistas de crédito. De posse do modelo de *credit scoring*, a instituição tem uma expectativa do comportamento do cliente, podendo assim escolher liberar ou não o crédito (VASCONCELLOS, 2004).

Segundo Hand e Henley (1998), *credit scoring* é o termo usado para descrever o processo que determina a chance dos clientes honrarem o crédito concedido. Uma prática comum é dividir os clientes entre “bons” e “maus”, sendo os “bons” clientes aqueles que não atrasam seus pagamentos e os “maus” clientes aqueles que atrasam ou não honram suas dívidas.

Segundo Thomas (2000), *credit scoring* é uma das técnicas de previsão mais importantes nas áreas financeiras e de varejo. O *credit scoring* vem sendo usado principalmente como uma maneira de prever a inadimplência, a fim de se preparar para o futuro. Com as conexões que estão sendo feitas entre *credit scoring* e modelos de propensão à venda, essas técnicas podem ser usadas também para prever a venda de produtos e o lucro que a empresa terá no futuro.

Crook et al. (2007) afirmam que o *credit scoring* é uma das aplicações de estatística e pesquisa operacional de maior sucesso, considerando seus impactos sociais. O uso de *credit scoring* facilita a avaliação e concessão de crédito, diminui os custos de crédito para quem não traz riscos, além de aumentar a competição entre instituições financeiras. Os autores acrescentam que o *credit scoring* também é usado para decidir quem é mais propenso a sanar as dívidas, quem deve receber uma mala direta e para identificar consumidores que podem receber um serviço ou produto antes de efetuar o pagamento.

Os dois indicadores mais utilizados para medir o poder de classificação de um modelo de *credit scoring* são o percentual de classificações corretas e o valor do teste de Kolmogorov-Smirnov (KS) (SELAU, 2008). O primeiro indicador é autoexplicativo. O segundo se baseia na diferença entre a distribuição acumulada de clientes “bons” e de clientes “maus” a partir dos seus resultados previstos pelo modelo; o indicador KS é dado pela diferença máxima entre esses dois casos para um mesmo resultado previsto (CROOK et al, 2007). A estatística do teste Kolmogorov-Smirnov é definida pela equação $KS = \max_{0 \leq s \leq 1} |F_m(s) - F_b(s)|$, $0 \leq KS \leq 100\%$ (equação 1), onde $F_m(s)$ é a frequência acumulada dos escores dos clientes “maus”, e $F_b(s)$ é a frequência acumulada dos escores dos clientes “bons”, e s é a classificação proposta pelo modelo para cada cliente (valor entre 0 e 1). Um dos problemas do indicador *KS* é que a maior diferença entre clientes “bons” e “maus” pode ocorrer em um ponto não interessante operacionalmente para o utilizador do modelo, como nos maiores escores previstos pelo modelo (THOMAS et al, 2002).

No âmbito de sua implementação, a determinação de um ponto de corte para determinar quais clientes terão seu crédito aprovado é uma decisão mais gerencial do que metodológica, visto que depende de critérios da empresa, tais como a taxa de aprovação e a proporção de clientes bons negados. Após a implementação, é necessária uma análise periódica do modelo, pois mudanças no perfil de clientes em relação ao perfil da amostra usada no desenvolvimento do modelo trarão perdas em sua efetividade (SELAU; RIBEIRO, 2009).

Existem diferentes abordagens para a obtenção de modelos de *credit scoring*. Rosenberg e Gleit (1994) já indicavam que a técnica mais tradicionalmente usada é a análise discriminante. Hand e Henley (1998) acrescentam as árvores de decisão e regressão linear e logística como métodos alternativos. Para os autores, a popularidade dessas ferramentas deve-se a sua facilidade de entendimento, tanto para analistas quanto para usuários, o que não ocorre com ferramentas mais robustas, como as redes neurais.

2.1 REDES NEURAIAS

Uma rede neural é um modelo computacional de crescente interesse no desenvolvimento de modelos de *credit scoring*. Autores realizaram testes comparando o desempenho de redes neurais contra outros métodos. Tsai *et al.* (2009) compararam redes neurais com métodos de classificação clássicos, como regressões logísticas e análise discriminante, obtendo um melhor resultado em termos de acurácia nas previsões com o uso de redes neurais, em uma base de dados com 1900 clientes.

Desai *et al.* (1996) compararam redes neurais com regressão logística e análise discriminante usando dados de cooperativas de crédito, contando com dados de 3.000 clientes. As redes neurais se mostraram superiores a outros métodos quando a modelagem do *credit scoring* era customizada para cada cooperativa; o mesmo não se observou no caso de modelos genéricos, considerando informações de todas cooperativas. Considerando como métrica de avaliação a identificação de clientes “maus”, as redes neurais se mostraram superiores em ambos os cenários.

Yeh e Lien (2009) compararam técnicas de *data mining* na criação de modelo de *credit scoring* para clientes de bancos em Taiwan, em uma base de dados com 25.000 clientes. As técnicas testadas foram análise discriminante, regressão logística, classificador Naïve Bayes, redes neurais e árvores de decisão. Apesar dos resultados similares obtidos utilizando esses métodos, as redes neurais apresentaram maior acurácia na classificação. As redes neurais foram a única técnica possível de utilização quando o objetivo era estimar a probabilidade de inadimplência de clientes. Em um contexto de análise de risco, essa informação pode ser mais importante do que dividir os clientes binariamente entre “bons” e “maus”.

Abdou *et al.* (2008) compararam técnicas de *credit scoring* usando informações do mercado de crédito Egípcio, em um banco de dados com informações de 581 clientes. As técnicas de análise discriminante, análise *probit* e regressões logísticas foram comparadas com dois métodos de redes neurais, *probabilistic neural nets* e *multi-layer feed-forward nets*. Para cada de rede neural foram feitos 20 treinos com diferentes tamanhos de grupos de teste, a fim de verificar qual se adaptava melhor às mudanças. Os métodos de redes neurais foram superiores às demais técnicas, sendo o modelo *probabilist neural net* melhor na média dos 20 treinos e o modelo *multi-layer feed-forward nets* o que teve o melhor desempenho individual,

considerando todas as redes feitas. Os autores identificaram os modelos de redes neurais como superiores na identificação de clientes “bons” do que de clientes “maus”.

Existem diferentes métodos usados para desenvolvimento de redes neurais. West (2000) comparou a acurácia de cinco modelos de redes neurais usando *credit scoring*; são eles: *multilayer perceptron*, *mixture-of-experts*, *radial basis function*, *learning vector quantization* e *fuzzy adaptive resonance*. Os modelos foram testados em duas bases de dados reais. Embora o *multilayer perceptron* seja o modelo clássico de rede neural, aqueles que apresentaram melhor resultado em *credit scoring* foram o *mixture-of-experts* e o *radial basis function*. O autor ainda identifica que as redes neurais, devido a sua natureza estocástica, podem apresentar o problema da não convergência; para atingir o melhor resultado, o autor realizou 10 treinamentos para cada rede neural.

Zhao et al. (2015) propuseram melhorias no uso de redes neurais na modelagem de *credit scoring*, em particular no que diz respeito à razão entre clientes “bons” e “maus”, pois normalmente as bases para treino de modelos tem mais casos de clientes “bons” do que “maus”, o que pode enviesar o modelo. É proposta uma nova metodologia de partição das bases de treino e teste, que faz com que as bases tenham a mesma proporção entre classes. Com isso, obteve-se uma melhora de 5% na acurácia do modelo, se comparado com um modelo feito com partições tradicionais. Os autores também fizeram testes variando o número de *neurons* da camada intermediária (entre 6 e 39) e concluíram que, com mais *neurons* na camada intermediária da rede neural, o erro do modelo resultava menor.

Lessmann et al. (2015) compararam 41 técnicas usadas em artigos sobre desenvolvimento de modelos de *credit scoring*. Apesar das redes neurais se mostrarem uma das melhores técnicas, os autores afirmam que o uso de novas técnicas pode ter estagnado e que o foco deveria ser redirecionado para outros problemas de criação de modelos de *credit scoring* (por exemplo, seleção de variáveis).

2.2 TRATAMENTO DE VARIÁVEIS

Na rede neural, a variável dependente pode ser influenciada tanto por variáveis quantitativas quanto variáveis qualitativas. A mensuração de variáveis quantitativas é feita por alguma escala, mas variáveis qualitativas não possuem escala, visto que estas indicam a presença ou ausência de alguma qualidade ou atributo. Para quantificar esses atributos, são construídas variáveis *dummy*, que são variáveis com valores de 0 ou 1, indicando a ausência ou presença do atributo (HARDY, 1993).

O uso de variáveis *dummy* em modelos estatísticos traz o benefício de facilidade de implementação de modelos e facilidade de interpretação. Além disso, o uso das *dummy* não é restrito a apenas variáveis categóricas, pois é possível criar faixas para variáveis contínuas a partir da relação dos seus atributos com a variável dependente (GARAVAGLIA; SHARMA, 1998).

Para realizar agrupamento de variáveis em modelos de *credit scoring* é usado o índice do risco relativo, dado pela razão do percentual de clientes “bons” da faixa escolhida sobre o percentual de clientes “maus” que se encontram na mesma faixa da variável. Quanto mais os percentuais de clientes “bons” e “maus” se diferem para atributos de uma mesma variável, maior será a utilidade dessa variável para o modelo. Atributos que têm proporção de “bons” e “maus” muito similares são considerados neutros e não são utilizados no desenvolvimento do modelo (LEWIS, 1992).

Selau (2008) dividiu variáveis *dummy* para modelos de *credit scoring* através do risco relativo. Assim, variáveis quantitativas foram divididas em várias faixas de *dummy*, cada uma com um risco relativo distinto. Com isso, evitam-se problemas decorrentes da não linearidade de algumas das variáveis na construção do modelo. Um exemplo é a variável idade, já que o aumento da idade não trará um aumento ou diminuição linear na inadimplência do cliente. Variáveis com grande número de atributos, como profissão, CEP e cidade de nascimento, foram agrupadas em grupos similares de risco relativo para, então, serem transformadas em *dummy*.

2.3 SELEÇÃO STEPWISE DE VARIÁVEIS

Devido à grande quantidade de variáveis disponíveis, são necessários métodos para fazer a sua seleção, a fim de retirar variáveis redundantes e escolher as melhores para o modelo. O método *stepwise* se baseia na retirada ou inserção de variáveis a fim de, com essa mudança, melhorar o modelo. É implementada tanto da forma *forward* (inicialmente o modelo começa sem variáveis, sendo adicionada a cada etapa a variável de maior significância, até que a adição de novas variáveis não traga benefícios para o modelo) quanto na forma *backward* (o modelo inicial conta com todas as variáveis e, a cada etapa, é retirada a variável de menor significância, até a retirada de uma variável não melhorar o modelo) (RENCHE, 2003).

Sung (1998) fez a implementação do método *stepwise* em redes neurais, onde se media o erro quadrado da rede neural a cada retirada de variável da matriz de entrada, com o

objetivo de encontrar combinação de variáveis que minimiza o erro. Conclui-se que o método é capaz de identificar a importância de cada variável, retirando primeiro as variáveis menos importantes. No entanto, no caso de variáveis redundantes ou com erro, o método determinou incorretamente a sua ordem de importância. Hair *et al.* (2005) discutem esse mesmo ponto, no qual o método *stepwise* pode não separar variáveis que tenham multicolinearidade entre si. Os autores sugerem que se faça uma avaliação prévia de cada variável relativamente à variável dependente.

De acordo com Gevrey *et al.* (2003), que fizeram uma análise e comparação do método *stepwise* com diversos métodos de seleção de variáveis em redes neurais, o método *stepwise* é capaz de classificar as variáveis pela sua ordem de importância na saída do modelo. O principal problema do método é a necessidade de treino de uma nova rede neural para cada interação de retirada ou inserção de variáveis, o que consome muitos recursos e tempo. Os autores propõem um aperfeiçoamento do método, onde apenas um modelo com todas variáveis é treinado, e as variáveis são retiradas uma a uma: quanto maior o erro médio quadrado do modelo quando retirada a variável, maior sua importância no modelo.

3. PROCEDIMENTOS METODOLÓGICOS

Nesta seção do trabalho é especificado o método adotado para atingir os objetivos propostos. Primeiramente, apresenta-se o cenário do foco do estudo, seguido da classificação da pesquisa e, por fim, o método de trabalho proposto.

3.1 DESCRIÇÃO DO CENÁRIO

A necessidade do uso de *credit scoring* por instituições financeiras e bancos para concessão de crédito já ocorre há vários anos. Devido à intensa competitividade no setor, há grande exploração de novas técnicas e aprimoramentos para obter melhores resultados.

Devido à natureza confidencial dos dados usados em modelos de *credit scoring*, instituições financeiras e bancos não fornecem tais informações. Em razão disso, a base de dados usada neste estudo é uma base pública de um banco de Taiwan, com informações de clientes de outubro de 2005. Nesta época, Taiwan estava em meio a uma crise financeira devido à concessão de limite a clientes não qualificados (YEH; LIEN, 2009). A base de dados contém informações de gênero, idade, nível educacional, estado civil, histórico de

atrasos, histórico de dívidas e pagamentos e valor de crédito concedido, além da informação se o cliente honrou sua dívida ou não.

3.2 CARACTERIZAÇÃO DO MÉTODO DE PESQUISA

O estudo é de natureza aplicada, visto que objetiva gerar conhecimento para aplicação prática, voltado para solução de problemas específicos (DA SILVA E MENEZES, 2001). A abordagem do estudo é quantitativa, pois os modelos sugeridos foram construídos por métodos estatísticos. A pesquisa possui objetivo exploratório, visto que, com a revisão de métodos e critérios, irá se propor uma melhoria na construção de modelos de *credit scoring*. Por fim, em relação aos procedimentos de pesquisa, o estudo pode ser classificado como estudo de caso, pois o problema não tem uma solução pré-definida, sendo necessária uma análise.

3.3 CARACTERIZAÇÃO DO MÉTODO DE TRABALHO

As etapas envolvidas para realização do estudo foram baseadas na sistemática de construção de modelos de *credit scoring* proposto por Selau e Ribeiro (2009). As etapas propostas são: (i) seleção da amostra, (ii) análise preliminar, (iii) construção do modelo, (iv) escolha do modelo.

A primeira etapa trata da seleção da amostra onde, de posse do banco de dados, é realizada uma primeira análise do conteúdo de cada campo e variável, verificando o tipo de cada variável (quantitativa ou qualitativa) e a presença ou não de observações faltantes. Após, é realizada a partição da base em porção de treino e porção de teste. Será usada a metodologia proposta por Zhao (2015), em que 80% dos dados são separados para treino do modelo e 20% para testes, mantendo a proporção de classes entre as porções.

Na segunda etapa é feita a análise preliminar, onde será analisada a separação de variáveis por atributos, segundo o seu risco relativo, que é a razão entre a proporção de clientes “bons” e clientes “maus” de um mesmo atributo. A divisão por risco relativo se dará utilizando os 7 agrupamentos propostos por Lewis (1992), sendo que atributos com risco relativo neutro não serão usados para criação do modelo (Figura 2). Após a seleção dos atributos de cada variável a serem utilizados na construção do modelo, serão criadas variáveis *dummy*, que indicarão a presença ou não do atributo.




Figura 2. Classes de risco relativo para agrupamento.

Na etapa seguinte é feita a construção dos modelos. Os modelos serão desenvolvidos usando redes neurais. Primeiramente, serão construídos dois modelos: um com as variáveis *dummy* separadas a partir do risco relativo, e outro sem o uso de variáveis *dummy*. Assim, será comparado o uso de variáveis *dummy* e risco relativo em modelos de *credit scoring*. Após, para cada modelo, será aplicada a seleção *stepwise* de variáveis, nas formas *forward* e *backward*, e através do método “*stepwise* aperfeiçoado”, proposto por Gevrey *et al.* (2003). Com isso, serão avaliados quais métodos de seleção *stepwise* melhoram o resultado de modelos de *credit scoring* e qual o melhor entre eles.

Na última etapa, será feita a escolha do modelo. Os modelos desenvolvidos serão avaliados utilizando a porção de teste da base de dados. As medidas de desempenho a serem usadas para avaliar os modelos são o percentual de classificações corretas e o teste de Kolmogorov-Smirnov (KS). O percentual de classificações corretas é medido pelo número de clientes classificados corretamente sobre o número total de casos analisados. A estatística do teste KS será calculada conforme apresentado na seção 2.

4. ESTUDO DE CASO

Nesta seção são apresentados os resultados obtidos na aplicação da metodologia proposta na seção 3.

4.1 SELEÇÃO DA AMOSTRA

As informações usadas para a criação do modelo foram extraídas de um banco de Taiwan. A amostra contém dados de 30.000 clientes com vencimento de cartão de crédito no mês de outubro de 2005. Os clientes são caracterizados por 23 variáveis (Tabela 1), além da informação se estava com pagamentos em atraso.

Variável	Descrição
LIMIT_BAL	Crédito concedido ao cliente
SEX	Homem, Mulher
EDUCATION	Pós-Graduação, Faculdade, Ensino Médio, Outros
MARRIAGE	Casado, Solteiro, Outros
AGE	Idade
PAY_0	Meses de atraso de pagamentos em setembro 2005
PAY_2	Meses de atraso de pagamentos em agosto 2005
PAY_3	Meses de atraso de pagamentos em julho 2005
PAY_4	Meses de atraso de pagamentos em junho 2005
PAY_5	Meses de atraso de pagamentos em maio 2005
PAY_6	Meses de atraso de pagamentos em abril 2005
BILL_AMT1	Valor da fatura em setembro 2005
BILL_AMT2	Valor da fatura em agosto 2005
BILL_AMT3	Valor da fatura em julho 2005
BILL_AMT4	Valor da fatura em junho 2005
BILL_AMT5	Valor da fatura em maio 2005
BILL_AMT6	Valor da fatura em abril 2005
PAY_AMT1	Valor de pagamentos em setembro 2005
PAY_AMT2	Valor de pagamentos em agosto 2005
PAY_AMT3	Valor de pagamentos em julho 2005
PAY_AMT4	Valor de pagamentos em junho 2005
PAY_AMT5	Valor de pagamentos em maio 2005
PAY_AMT6	Valor de pagamentos em abril 2005

Tabela 1. Variáveis para construção do modelo.

Quanto à classificação dos clientes em “bons” e “maus”, a distribuição dos 30.000 clientes está apresentada na Tabela 2.

Classificação Cliente	Quantidade	%
Bom	23.364	77,88
Mau	6.636	22,12
Total	30.000	100,00

Tabela 2. Distribuição dos clientes.

Aleatoriamente, foram separadas amostras de treino e teste do modelo, com proporções de 80% e 20%, respectivamente, mantendo a proporção de clientes “bons” e “maus” nas duas porções. A porção de teste ficou composta por 5.963 clientes, e a porção de treino ficou com 24.034 clientes.

4.2 ANÁLISE PRELIMINAR

Todas as variáveis foram analisadas através do cálculo do risco relativo, dividindo o percentual de clientes “bons” sobre o percentual de clientes “maus” de cada faixa da variável. Para variáveis qualitativas, foram criadas variáveis *dummy* para cada atributo possível da variável. Para variáveis quantitativas, foram criadas variáveis *dummy* pela separação do risco relativo entre as faixas de uma mesma variável. O resultado da criação das variáveis *dummy* se encontra na Tabela 3.

VARIÁVEL	BOM	MAU	TOTAL	%BOM	%MAU	RR	% CLIENTES	CLASSE DE RISCO
LIMIT_BAL								
até 100.000	6.475	2.717	9.192	34,59%	51,10%	0,68	38%	Mau
de 100.000 até 160.000	3.101	895	3.996	16,56%	16,83%	0,98	17%	Neutro
mais de 160.000	9.145	1.705	10.850	48,85%	32,07%	1,52	45%	Muito bom
SEX								
Masculino	7.203	2.304	9.507	38,48%	43,33%	0,89	40%	Mau
Feminino	11.518	3.013	14.531	61,52%	56,67%	1,09	60%	Neutro
EDUCATION								
Desconhecido	10	0	10	0,05%	0,00%		0%	Excelente
Pós-Graduação	6.859	1.641	8.500	36,64%	30,86%	1,19	35%	Bom
Graduação	8.533	2.641	11.174	45,58%	49,67%	0,92	46%	Neutro
Ensino Médio	2.983	1.007	3.990	15,93%	18,94%	0,84	17%	Mau
Outros	101	5	106	0,54%	0,09%	5,74	0%	Excelente
Desconhecido	199	16	215	1,06%	0,30%	3,53	1%	Excelente
Desconhecido	36	7	43	0,19%	0,13%	1,46	0%	Bom
MARRIAGE								
Desconhecido	42	4	46	0,22%	0,08%	2,98	0%	Excelente
Casado	8.422	2.565	10.987	44,99%	48,24%	0,93	46%	Neutro
Solteiro	10.067	2.680	12.747	53,77%	50,40%	1,07	53%	Neutro
Outros	190	68	258	1,01%	1,28%	0,79	1%	Mau
AGE								
até 30	5.964	1.741	7.705	31,86%	32,74%	0,97	32%	Neutro
de 30 a 40	7.140	1.859	8.999	38,14%	34,96%	1,09	37%	Neutro
mais de 40	5.617	1.717	7.334	30,00%	32,29%	0,93	31%	Neutro
PAY_0								
0	5.681	1.047	6.728	30,35%	19,69%	1,54	28%	Muito bom
1	10.333	1.513	11.846	55,19%	28,46%	1,94	49%	Muito bom
mais de 1	2.707	2.757	5.464	14,46%	51,85%	0,28	23%	Péssimo
PAY_2								
0	2.477	562	3.039	13,23%	10,57%	1,25	13%	Bom
0 até 2	14.703	2.780	17.483	78,54%	52,29%	1,50	73%	Muito bom
mais de 2	1.541	1.975	3.516	8,23%	37,15%	0,22	15%	Péssimo

Tabela 3. Faixas das variáveis *dummy* utilizadas na modelagem.

VARIÁVEL	BOM	MAU	TOTAL	%BOM	%MAU	RR	% CLIENTES	CLASSE DE RISCO
PAY_3								
0	6.685	1.359	8.044	35,71%	25,56%	1,40	33%	Bom
0 até 2	10.451	2.188	12.639	55,83%	41,15%	1,36	53%	Bom
mais de 2	1.585	1.770	3.355	8,47%	33,29%	0,25	14%	Péssimo
PAY_4								
0	6.637	1.397	8.034	35,45%	26,27%	1,35	33%	Bom
0 até 2	10.792	2.403	13.195	57,65%	45,19%	1,28	55%	Bom
mais de 2	1.292	1.517	2.809	6,90%	28,53%	0,24	12%	Péssimo
PAY_5								
0	6.605	1.422	8.027	35,28%	26,74%	1,32	33%	Bom
0 até 2	11.061	2.560	13.621	59,08%	48,15%	1,23	57%	Bom
mais de 2	1.055	1.335	2.390	5,64%	25,11%	0,22	10%	Péssimo
PAY_6								
0	3.106	795	3.901	16,59%	14,95%	1,11	16%	Bom
0 até 2	14.449	3.237	17.686	77,18%	60,88%	1,27	74%	Bom
mais de 2	1.166	1.285	2.451	6,23%	24,17%	0,26	10%	Péssimo
BILL_AMT1								
até 10.000	6.723	1.950	8.673	35,91%	36,67%	0,98	36%	Neutro
10.000 até 40.000	4.627	1.459	6.086	24,72%	27,44%	0,90	25%	Neutro
mais de 40.000	7.368	1.908	9.276	39,36%	35,88%	1,10	39%	Neutro
BILL_AMT2								
até 10.000	6.915	1.937	8.852	36,94%	36,43%	1,01	37%	Neutro
10.000 até 40.000	4.683	1.509	6.192	25,01%	28,38%	0,88	26%	Mau
mais de 40.000	7.113	1.871	8.984	37,99%	35,19%	1,08	37%	Neutro
BILL_AMT3								
até 10.000	7.026	1.953	8.979	37,53%	36,73%	1,02	37%	Neutro
10.000 até 40.000	4.923	1.579	6.502	26,30%	29,70%	0,89	27%	Mau
mais de 40.000	6.760	1.782	8.542	36,11%	33,52%	1,08	36%	Neutro
BILL_AMT4								
até 10.000	7.267	1.988	9.255	38,82%	37,39%	1,04	39%	Neutro
10.000 até 40.000	5.256	1.689	6.945	28,08%	31,77%	0,88	29%	Mau
mais de 40.000	6.190	1.635	7.825	33,06%	30,75%	1,08	33%	Neutro
BILL_AMT5								
até 10.000	7.609	2.055	9.664	40,64%	38,65%	1,05	40%	Neutro
10.000 até 40.000	5.276	1.727	7.003	28,18%	32,48%	0,87	29%	Mau
mais de 40.000	5.826	1.530	7.356	31,12%	28,78%	1,08	31%	Neutro
BILL_AMT6								
até 10.000	7.961	2.127	10.088	42,52%	40,00%	1,06	42%	Neutro
10.000 até 40.000	5.092	1.667	6.759	27,20%	31,35%	0,87	28%	Mau
mais de 40.000	5.650	1.517	7.167	30,18%	28,53%	1,06	30%	Neutro

Tabela 3. Faixas das variáveis dummy utilizadas na modelagem (Cont.).

VARIÁVEL	BOM	MAU	TOTAL	%BOM	%MAU	RR	% CLIENTES	CLASSE DE RISCO
PAY_AMT1								
até 1.500	5.842	2.416	8.258	31,21%	45,44%	0,69	34%	Mau
1.500 até 3.000	4.237	1.244	5.481	22,63%	23,40%	0,97	23%	Neutro
mais de 3.000	8.642	1.657	10.299	46,16%	31,16%	1,48	43%	Bom
PAY_AMT2								
até 1.500	6.338	2.508	8.846	33,86%	47,17%	0,72	37%	Mau
1.500 até 3.000	4.113	1.199	5.312	21,97%	22,55%	0,97	22%	Neutro
mais de 3.000	8.270	1.610	9.880	44,17%	30,28%	1,46	41%	Bom
PAY_AMT3								
até 1.000	5.557	2.220	7.777	29,68%	41,75%	0,71	32%	Mau
1.000 até 3.000	5.725	1.688	7.413	30,58%	31,75%	0,96	31%	Neutro
mais de 3.000	7.439	1.409	8.848	39,74%	26,50%	1,50	37%	Bom
PAY_AMT4								
até 1.000	6.647	2.486	9.133	35,51%	46,76%	0,76	38%	Mau
1.000 até 3.000	5.144	1.511	6.655	27,48%	28,42%	0,97	28%	Neutro
mais de 3.000	6.930	1.320	8.250	37,02%	24,83%	1,49	34%	Bom
PAY_AMT5								
até 1.000	6.646	2.441	9.087	35,50%	45,91%	0,77	38%	Mau
1.000 até 3.000	5.105	1.507	6.612	27,27%	28,34%	0,96	28%	Neutro
mais de 3.000	6.970	1.369	8.339	37,23%	25,75%	1,45	35%	Bom
PAY_AMT6								
até 1.000	6.810	2.534	9.344	36,38%	47,66%	0,76	39%	Mau
1.000 até 3.000	4.979	1.458	6.437	26,60%	27,42%	0,97	27%	Neutro
mais de 3.000	6.932	1.325	8.257	37,03%	24,92%	1,49	34%	Bom

Tabela 3. Faixas das variáveis *dummy* utilizadas na modelagem (Cont.).

4.3 CONSTRUÇÃO DO MODELO

Os modelos de *credit scoring* foram construídos na linguagem de programação *Python*, com o uso do *framework Keras* para a construção das redes neurais. Na construção de todos os modelos, foram testados diferentes tamanhos de rede e parâmetros para atingir melhores resultados. O resultado final de cada modelo foi feito sobre a média de diferentes porções de base de teste.

Na construção dos modelos com o uso do método *stepwise* para seleção de variáveis, foram desenvolvidas rotinas computacionais que treinavam a rede neural tanto na forma *forward*, *backward* quanto no método “*stepwise* aperfeiçoado”. Para a construção desses modelos, foram mantidos os mesmos tamanhos de rede e parâmetros dos modelos sem seleção de variáveis.

4.3.1 MODELO SEM *DUMMY*

Para a construção do modelo sem variáveis *dummy*, a rede com melhores resultados teve duas camadas intermediárias, a primeira com 46 *neurons* e a segunda com 12. A taxa de aprendizado usada foi de 10^{-5} , com *batch size* de 30 e 1000 iterações. O percentual de classificações corretas do modelo na porção de teste foi de 67,26% e seu KS de 27,70%.

Perc. Clientes	Clientes Bons	Clientes Maus	Total	%Bons	%Maus	%Bom Acum.	%Mau Acum.	KS
10%	389	207	596	8,38%	15,69%	8,38%	15,69%	7,32%
10-20%	382	214	596	8,23%	16,22%	16,61%	31,92%	15,31%
20-30%	379	217	596	8,16%	16,45%	24,77%	48,37%	23,60%
30-40%	422	174	596	9,09%	13,19%	33,86%	61,56%	27,70%
40-50%	465	132	597	10,02%	10,01%	43,87%	71,57%	27,70%
50-60%	490	106	596	10,55%	8,04%	54,43%	79,61%	25,18%
60-70%	505	91	596	10,88%	6,90%	65,30%	86,50%	21,20%
70-80%	513	83	596	11,05%	6,29%	76,35%	92,80%	16,45%
80-90%	546	50	596	11,76%	3,79%	88,11%	96,59%	8,48%
90-100%	552	45	597	11,89%	3,41%	100,00%	100,00%	0,00%
Total	4.643	1.319	5.962					

Tabela 4. KS Modelo sem *dummy*.

4.3.2 MODELO STEPWISE SEM VARIÁVEIS *DUMMY*

No modelo sem variáveis *dummy* com seleção *stepwise*, a rede com melhor resultado foi uma seleção *backward* de variáveis, que retirou a variável “SEX” do modelo. Esse modelo teve um percentual de classificações corretas na porção de teste de 66,34% e um KS de 30,13%.

Perc. Clientes	Clientes Bons	Clientes Maus	Total	%Bons	%Maus	%Bom Acum.	%Mau Acum.	KS
10%	375	221	596	8,08%	16,76%	8,08%	16,76%	8,68%
10-20%	371	225	596	7,99%	17,06%	16,07%	33,81%	17,75%
20-30%	408	188	596	8,79%	14,25%	24,85%	48,07%	23,21%
30-40%	404	192	596	8,70%	14,56%	33,56%	62,62%	29,07%
40-50%	454	143	597	9,78%	10,84%	43,33%	73,46%	30,13%
50-60%	497	99	596	10,70%	7,51%	54,04%	80,97%	26,93%
60-70%	510	86	596	10,98%	6,52%	65,02%	87,49%	22,47%
70-80%	529	67	596	11,39%	5,08%	76,42%	92,57%	16,15%
80-90%	532	64	596	11,46%	4,85%	87,87%	97,42%	9,55%
90-100%	563	34	597	12,13%	2,58%	100,00%	100,00%	0,00%
Total	4.643	1.319	5.962					

Tabela 5. KS Modelo sem *dummy stepwise* .

4.3.3 MODELO COM VARIÁVEIS *DUMMY*

Para a construção do modelo com variáveis *dummy*, a rede que obteve melhores resultados teve duas camadas intermediárias, a primeira com 46 *neurons* e a segunda com 12. Foi usada uma camada de *dropout* após cada camada intermediária, com seleção aleatória de 50% dos pesos a cada interação. A taxa de aprendizado usada foi de 10^{-2} , com uma taxa de decréscimo de 10^{-12} a cada iteração, com *batch size* de 128 e 200 iterações. Esse modelo teve um percentual de classificações corretas de 73,95%, com um KS de 42,27%.

Perc. Clientes	Clientes Bons	Clientes Maus	Total	%Bons	%Maus	%Bom Acum.	%Mau Acum.	KS
10%	196	400	596	4,22%	30,33%	4,22%	30,33%	26,10%
10-20%	345	251	596	7,43%	19,03%	11,65%	49,36%	37,70%
20-30%	417	179	596	8,98%	13,57%	20,63%	62,93%	42,29%
30-40%	489	107	596	10,53%	8,11%	31,17%	71,04%	39,87%
40-50%	498	99	597	10,73%	7,51%	41,89%	78,54%	36,65%
50-60%	514	82	596	11,07%	6,22%	52,96%	84,76%	31,80%
60-70%	527	69	596	11,35%	5,23%	64,31%	89,99%	25,68%
70-80%	543	53	596	11,70%	4,02%	76,01%	94,01%	18,00%
80-90%	558	38	596	12,02%	2,88%	88,02%	96,89%	8,87%
90-100%	556	41	597	11,98%	3,11%	100,00%	100,00%	0,00%
Total	4.643	1.319	5.962					

Tabela 6. KS Modelo com variáveis *dummy* .

4.3.4 MODELO *STEPWISE* COM VARIÁVEIS *DUMMY*

No modelo com variáveis *dummy* e seleção *stepwise*, a melhor rede foi uma seleção *backward* de variáveis que retiraram as variáveis “MARRIAGE_2” e “PAY_0_2” do modelo. O modelo teve um percentual de classificações corretas de 74,10% e KS de 42,49%.

Perc. Clientes	Clientes Bons	Clientes Maus	Total	%Bons	%Maus	%Bom Acum.	%Mau Acum.	KS
10%	204	392	596	4,39%	29,72%	4,39%	29,72%	25,33%
10-20%	326	270	596	7,02%	20,47%	11,42%	50,19%	38,77%
20-30%	426	170	596	9,18%	12,89%	20,59%	63,08%	42,49%
30-40%	489	107	596	10,53%	8,11%	31,12%	71,19%	40,07%
40-50%	505	92	597	10,88%	6,97%	42,00%	78,17%	36,17%
50-60%	513	83	596	11,05%	6,29%	53,05%	84,46%	31,41%
60-70%	532	64	596	11,46%	4,85%	64,51%	89,31%	24,80%
70-80%	554	42	596	11,93%	3,18%	76,44%	92,49%	16,06%
80-90%	539	57	596	11,61%	4,32%	88,05%	96,82%	8,77%
90-100%	555	42	597	11,95%	3,18%	100,00%	100,00%	0,00%
Total	4.643	1.319	5.962					

Tabela 7. Modelo *stepwise* com variáveis *dummy*.

4.4 ESCOLHA DO MODELO

Os 4 modelos foram comparados relativamente às duas medidas de desempenho utilizadas neste trabalho. Os resultados estão apresentados na Tabela 8.

Modelo	Percentual Classificação Corretas	KS
Sem <i>dummy</i>	67,26%	27,70%
<i>Stepwise</i> sem <i>dummy</i>	66,34%	30,13%
Com <i>dummy</i>	73,95%	42,29%
<i>Stepwise</i> com <i>dummy</i>	74,10%	42,49%

Tabela 8. Comparação modelos

Em relação ao percentual de classificações corretas, os modelos construídos com variáveis *dummy* apresentaram resultados superiores aos demais. Avaliando-se pelo KS, os modelos com uso de *dummy* apresentam separação superior em praticamente todos os pontos em relação aos modelos sem variáveis *dummy* (Gráfico 1). Além disso, o número de interações necessárias nas redes neurais com o uso de *dummy* é menor, diminuindo o tempo necessário para criação de um modelo.

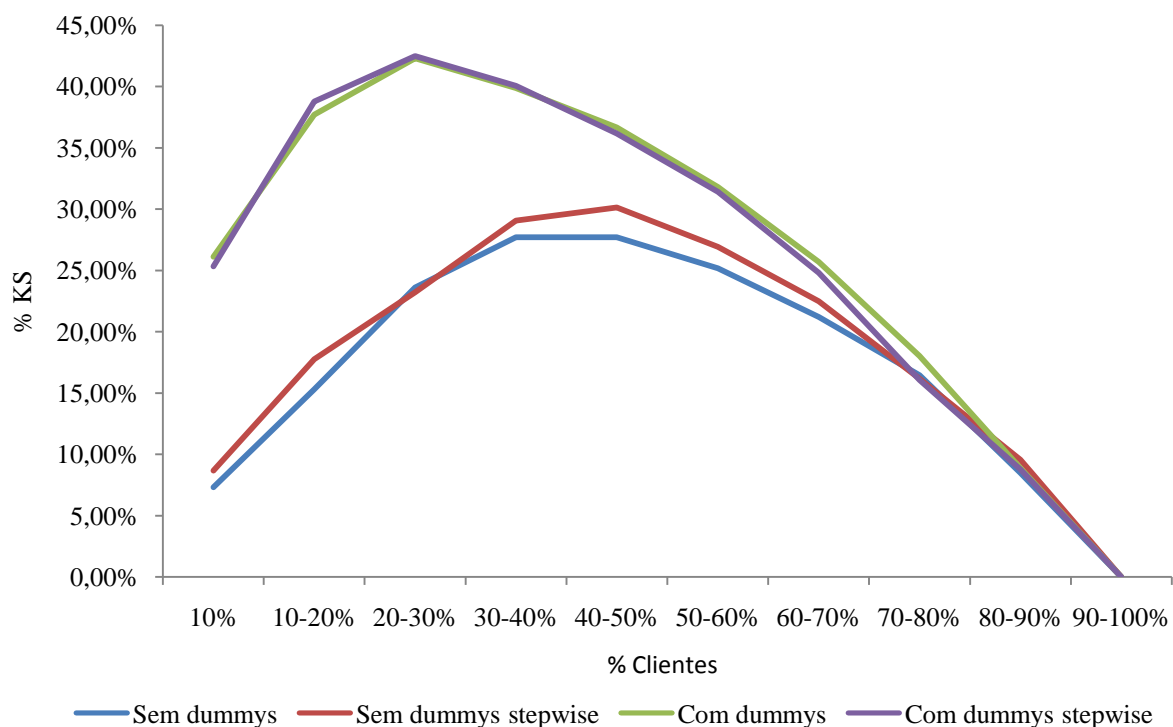


Gráfico 1. Comparação KS modelos por % de clientes.

Com relação a seleção *stepwise* de variáveis, os resultados apresentaram um pequeno acréscimo no indicador KS, em relação ao seu não uso (crescimento de 8,7% no KS sem *dummy* e 0,46% com *dummy*). No entanto, foi exigida uma grande repetição de treinamentos de rede neurais, o que consumiu muito tempo. O uso de seleção *stepwise*, consumiu, em média, 15 vezes mais tempo que seu não uso.

5. IMPLICAÇÕES GERENCIAIS

Se tratando de crédito, um dos mais importantes indicadores para as empresas é a inadimplência, ou seja, o percentual de clientes que não pagaram suas dívidas sobre o número total de clientes. Como se pode verificar no Gráfico 2, os modelos com variáveis *dummy* apresentam inadimplência média de 65% nos 10% clientes com menores escores previstos pelo modelo, contra 35%, em média, do modelo sem variáveis *dummy*. Isso mostra que o modelo ajuda a separar os clientes “bons” dos clientes “maus”, agrupando os clientes “maus” nas primeiras faixas de escores previstos pelo modelo.

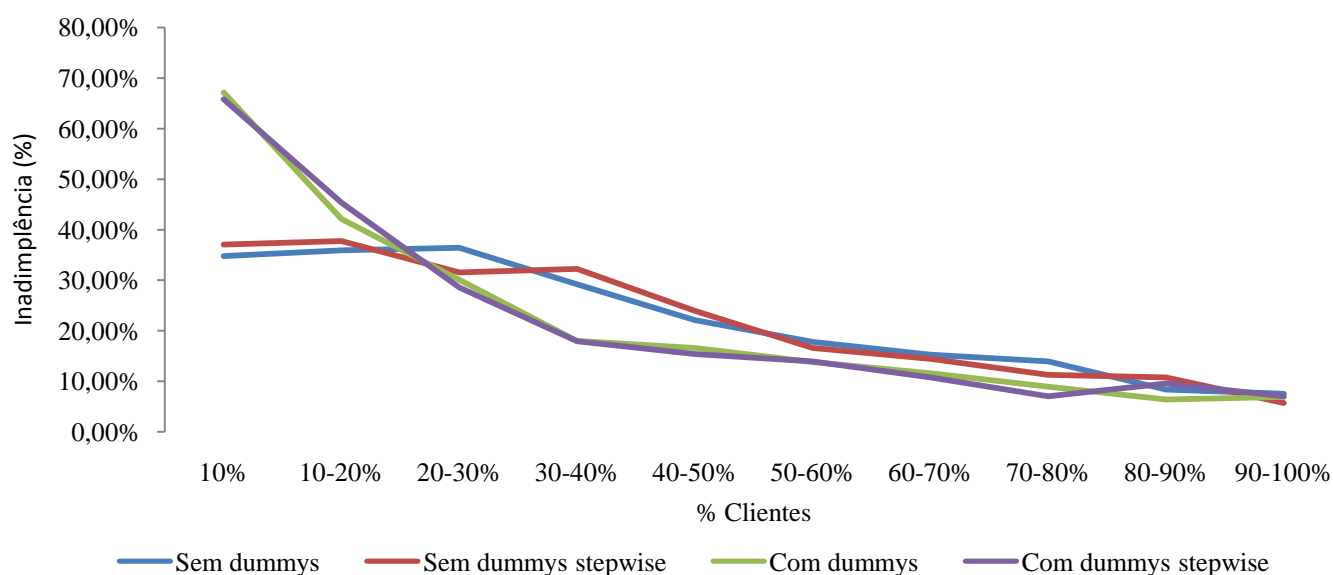


Gráfico 2. Inadimplência dos clientes.

Exemplificando a separação dos modelos desenvolvidos, se a instituição financeira desejasse que a inadimplência dos seus clientes com crédito fosse de 12%, o pior modelo (4.3.1) reprovaria 54% dos clientes, enquanto o melhor (4.3.4) reprovaria apenas 28% (Tabela 9).

Modelo	Clientes aprovados	Inadimplência	% Clientes aprovados	Clientes Reprovados
Sem dummy	2759	12,00%	46%	54%
Stepwise sem dummy	3053	11,99%	51%	49%
Com dummy	4243	12,00%	71%	29%
Stepwise com dummy	4301	12,02%	72%	28%

6. CONCLUSÃO

Modelos de *credit scoring* são cada vez mais necessários para bancos e instituições financeiras liberarem crédito com maior precisão, resultando numa menor inadimplência. Redes neurais são uma das principais ferramentas utilizadas para construção desses modelos.

O objetivo desse estudo era analisar a construção de modelos de *credit scoring* com redes neurais, avaliando se o uso de variáveis *dummy* e método de separação *stepwise* traziam melhoras ao resultado do modelo.

Nesse trabalho, foram desenvolvidas quatro redes neurais sobre a mesma base de clientes. Foram feitas combinações entre o uso ou não de variáveis *dummy* e separação de variáveis *stepwise*. O modelo base, sem uso de *dummy* e separação *stepwise*, foi o que teve o pior resultado, com um percentual de classificações corretas de 67% e KS de 27%. O modelo

que teve o melhor resultado foi com uso de *dummy* e separação *stepwise* , com um percentual de classificações corretas de 74,10% e KS de 42,49%.

Embora o modelo com melhor resultado tenha sido o com uso de *dummy* e separação *stepwise*, o uso do método de separação *stepwise* mostrou pouco acréscimo ao resultado do modelo(apenas 0,46% de aumento de KS em relação ao segundo melhor modelo, apenas com variáveis *dummy*) quando comparado com o tempo elevado que esse método acrescenta à construção do modelo (em média 15 vezes maior).

O uso de variáveis *dummy* se provou uma técnica com grande potencial de melhora de modelos de *credit scoring* de redes neurais, pois trouxe grandes resultados (crescimento de 52% de KS sobre o modelo sem *dummy*) sem trazer acréscimos de tempo a sua construção. Essa grande melhora se deve ao fato das dummies retirarem as diferenças de escalas existente entre as variáveis da base.

Como sugestões para trabalhos futuros são sugeridos: a utilização do método de variáveis *dummy* e separação *stepwise* em outras ferramentas de construção de modelos de *credit scoring*, como árvores de decisão; o uso de redes neurais com estruturas de redes diferentes da apresentada nesse trabalho; e a aplicação dos métodos utilizados nesse trabalho em bases de dados com maior número de clientes e variáveis.

O código usado para a construção desse estudo está disponível em <https://github.com/pedroschoen/analise-de-credit-scoring-utilizando-redes-neurais>.

Agradeço a UCI machine learning repository pela disponibilização da base usada para esse estudo.

REFERÊNCIAS

ABDOU, H.; POINTON, J.; EL-MASRY A. Neural nets versus conventional techniques in credit scoring in Egyptian banking. **Expert systems with applications**, v.46, p. 1275-1292, 2008.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**, 2ª ed, Rio de Janeiro: LTC, 2007.

CROOK, J. N.; EDLEMAN, D. B.; THOMAS, L. C. Recent developments in consumer credit risk assessment. **European Journal of Operational Research**, p.1447-1465 ,2007

DESAI, V. S.; CROOK, J. N.; OVERSTREET, G. A. A comparison of neural networks and linear scoring models in the credit union environment. **European Journal of Operational Research**, v.95 p.24-37, 1996

DINH, T.H.T.; KLEIMEIER S. A credit scoring model for Vietnam's retail banking market. **International review of financial analysis**, v.16 , p. 471-495, 2007.

GARAVAGLIA, S.; SHARMA, A. **A smart guide to dummy variables: Four applications and a macro**. Proceedings of the Northeast SAS Users Group Conference, p.43 ,1998.

GEVREY, M.; DIMOPOULOS, I.; LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological modelling*, v.160, p.249-264. , 2003

HAND, D. J.; HENLEY W. E. Statistical Classification Methods in Consumer Credit scoring: a review. **Journal of the Royal Statistical Society. Series A, Statistics in society**, v.160, p. 523-541, 1998.

HAIR, J.F.; ANDERSON, R.E.; BABIN, B.J. AND BLACK, W.C. **Análise multivariada de dados**. 5 ed. Porto Alegre: Bookman, 2005.

HARDY, M.A. **Regression with dummy variables**. Sage, 1993.

LESSMANN, S.; BAESSENS, B.; SEOW, H.V.; THOMAS, L.C.; Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. **European Journal of Operational Research**. V.247, p.124-136, 2015

LEWIS, E. M. **An Introduction to Credit scoring**. San Rafael: Fair, Isaac and Co., Inc. 1992.

RENCHER, A.C. **Methods of Multivariate Analysis**, 2ª ed, Cary: Wiley, 2003.

SELAU, L. P. R. **Construção de Modelos de Previsão de Risco de Crédito**. Dissertação (Mestrado em Engenharia da Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul , 2008.

SELAU, L. P. R. ; RIBEIRO, J. L. D. Uma sistemática para construção e escolha de modelos de previsão de risco de crédito. **Revista Gestão e Produção**, v. 16, p. 398-413, 2009.

DA SILVA, E.L.; MENEZES, E.M. **Metodologia da pesquisa e elaboração de dissertação**. Florianópolis, UFSC, 5(6). 2001

SUNG, A. H. Ranking importance of input parameters of neural networks. **Expert Systems with Applications**, v.15, p.405-411, 1998

ROSENBERG, E.; GLEIT, A. Quantitative methods in credit management: a survey. **Operations research**, v.42 p.589-613, 1994

VASCONCELLOS, R. S. **Modelos de Escoragem de Crédito Aplicados a Empréstimo Pessoal com Cheque**. Rio de Janeiro, 2004. Dissertação (Mestrado em Finanças e Economia Empresarial) – Escola de Pós-Graduação em Economia, Fundação Getúlio Vargas.

YEH, I.-C.; LIEN, C.-H. The comparisons of data mining techniques for the predictive accuracy of probability of default of credit card clients. **Expert Systems with Applications**, v.36 , p. 2473–2480, 2009.

THOMAS, L. C. A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers. **International journal of forecasting**, v.16, p149-172, 2000

THOMAS L.C.; EDELMAN D.B, CROOK J.N. Credit scoring and its applications.Siam; 2002.

TSAI, M. C. ; LIN, S. P.; CHENG, C. C.; & LIN, Y. P. The consumer loan default predicting model—An application of DEA–DA and neural network.**Expert Systems with applications**, v.36 p.11682-11690, 2009

WEST, D. Neural network credit scoring models.**Computers & Operations Research**, v.27, p.1131-1152, 2000.

ZHAO, Z.; XU, S.; KANG, B. H.; KABIR, M. M. J.; LIU, Y.; WASINGER, R. Investigation and improvement of multi-layer perceptron neural networks for credit scoring. **Expert Systems withApplications**, v.42, p.3508-3516, 2015.