

Classificação de portfólio de créditos não-performados utilizando redes neurais artificiais *Multilayer Perceptron*

Flávio Clésio Silva de Souza (UNINOVE – SP/Brasil) - flavioclesio@gmail.com
• Av. Francisco Matarazzo, 364, Água Branca, 01156-050, São Paulo-SP, (55) 11-3665-9087
Renato José Sassi (UNINOVE – SP/Brasil) - sassi@uninove.br

RESUMO O objetivo da presente pesquisa é realizar a aplicação da técnica de redes neurais do tipo *Multilayer Perceptron* (MLP) na criação dos modelos de classificação de um portfólio de créditos inadimplidos não-performados (NPLs – *Non-Performing Loans*) para classificação destes derivativos de crédito. Os créditos NPL são caracterizados como o montante relativo a empréstimos que não foram pagos e que já estão vencidos por mais de 90 dias. Uma vez que esses títulos por força de legislação são movidos para perdas, Fundos de Investimento em Direitos Creditórios (FIDC) realizam a compra dessas dívidas junto a essas instituições e realizam o processo de recuperação desse crédito. Com a utilização de redes neurais foram criados modelos de classificação relativos à posterior recuperação dessas dívidas. Para a avaliação de desempenho dos modelos foram apresentadas métricas de avaliação da classificação relativas às redes neurais com diferentes arquiteturas. Os resultados com a classificação foram satisfatórios tendo em vista que os modelos de classificação tiveram sucesso conforme a estrutura de custos econômicos apresentada.

Palavras-chave Créditos Não-Performados. Redes Neurais Artificiais. *Multilayer Perceptron*. *Non-Performing Loans*. Créditos Inadimplidos.

ABSTRACT *The purpose of the present research is to apply a Multilayer Perceptron (MLP) neural network technique to create classification models from a portfolio of Non-Performing Loans (NPLs) to classify this type of credit derivative. These credit derivatives are characterized as the amount of loans that were not paid and are already overdue more than 90 days. Since these titles are, because of legislative motives, moved by losses, Credit Rights Investment Funds (FDIC) performs the purchase of these debts and the recovery of the credits. Using the Multilayer Perceptron (MLP) architecture of Artificial Neural Network (ANN), classification models regarding the posterior recovery of these debts were created. To evaluate the performance of the models, evaluation metrics of classification relating to the neural networks with different architectures were presented. The results of the classifications were satisfactory, given the classification models were successful in the presented economics costs structure.*

Keywords *Multilayer Perceptron. Non-Performing Loans. Non-Performing Assets. Artificial Neural Networks. Defaulted Loans.*

1. INTRODUÇÃO

Alguns dos problemas relacionados às decisões financeiras sobre portfólios de créditos não-performados (Non-Performing Loans - NPL) são a classificação e a posterior construção de um modelo de recuperação desses créditos inadimplidos. De acordo com o tipo de portfólio adquirido são observados fatores como viabilidade econômica e estratégia de investimentos na recuperação desses créditos.

Inserido neste cenário complexo de negócios, gestores de Fundos de Investimento em Direitos Creditórios (FIDC) especializados em aquisição dessas dívidas devem criar um método de recuperação desses créditos já inadimplidos levando em questão variáveis ligadas características relativas à liquidação dessas dívidas.

Dessa forma, para obter o melhor retorno possível na recuperação desses créditos, um modelo de recuperação deve ser construído baseando-se em variáveis que classifiquem os clientes inadimplentes, para posterior elaboração de estratégias de recuperação desses créditos através das características dos clientes que saíram da situação de inadimplência.

O problema principal em NPLs é que este tipo de crédito obedece a uma dinâmica distinta de classificação de crédito comum. Esta distinção se dá na forma de que o crédito já foi cedido ao cliente, e o mesmo não realizou o pagamento. Dessa forma a maior dificuldade desse problema é realizar uma classificação através das características dos clientes que já pagaram os débitos inadimplidos em algum momento do tempo, e atribuir uma determinada classificação. Em outras palavras, este problema ultrapassa a complexidade de um modelo de escoragem de crédito (*Credit Scoring*) no qual o problema ocorre *a posteriori*, isto é, após o evento de inadimplência.

Dentre as técnicas utilizadas para classificação destacam-se: a Regressão Linear e Múltipla, Árvores de Decisão, Algoritmos Genéticos, *Rough Sets* e a Classificação Bayesiana (HARREL, 2001). Outra técnica utilizada em classificação aplicada na área de finanças são as Redes Neurais Artificiais (RNAs) que tem os seus conceitos básicos explorados nos trabalhos de Quinlan (1986), Breiman (*et al.*, 1984), Berger (1985), McNelis (2005) e Han e Kamber (2000).

O objetivo desse trabalho foi realizar a classificação de créditos inadimplidos aplicando RNAs que diante da característica não linear do problema de crédito possa apresentar um bom grau de generalização de seus modelos para dar suporte à decisão e na criação de modelos de recuperação de NPLs.

Para tanto foram criados cinco modelos de redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) com diferentes parâmetros para verificar se há diferenças significativas em relação à parametrização destes modelos. Uma estrutura de custos econômicos relativos à avaliação dos modelos também foi aplicada para validação adicional (KOHAVI; PROVOST, 2011), haja vista que trata-se de um modelo que lida com uma abordagem sensível aos custos econômicos envolvidos.

Através da aplicação de RNA foram criados cinco modelos de diferentes configurações arquiteturas, no qual dentre esses modelos chegou-se à acurácia de 85.88%. Além de sua acurácia global os modelos foram avaliados utilizando a abordagem sensível ao custo. Isso fez-se necessário devido ao fato de que o modelo de classificação deve levar em consideração os custos econômicos; os quais recompensam as classificações corretas e penaliza as classificações erradas feitas pela RNA.

Inserir parágrafo apresentando de forma breve os resultados alcançados pela pesquisa.

Este artigo está organizado da seguinte forma: Na Seção 2 são apresentados conceitos relativos aos NPLs, na Seção 3 é apresentada a MLP, na Seção 4 é descrita a metodologia experimental utilizada neste artigo, na Seção 5 são apresentados os resultados dos experimentos e as discussões que suportam o trabalho, na Seção 6 são expostas as considerações finais.

2. REVISÃO DE LITERATURA

2.1. CRÉDITOS NÃO-PERFORMADOS (*NON-PERFORMING LOANS*)

A definição de Crédito Não-Performado (Non Performing Loans - NPLs) é baseada na provisão de créditos inadimplentes acima do limite de 90 dias e abrangem pessoas jurídicas e pessoas físicas de acordo com o Fundo Monetário Internacional (2013).

O problema desses NPLs é exposto de acordo com o Índice de NPLs que é um dos indicadores chave para atestar a qualidade, o grau de risco e a solvência dos bancos. Se uma instituição bancária tem um índice de NPLs elevado é uma indicação que o portfólio de crédito está em deteriorado (HERRERIAS; MORENO, 2013).

A classificação em termos de limites de dias para caracterização de um crédito não-performados é determinada de acordo com cada país e a sua regulação bancária, mas de maneira geral consideram-se os NPLs quando o mesmo ultrapassa 90 dias após o último vencimento (INTERNATIONAL MONETARY FUND, 2013).

Os motivos que causam a inadimplência, e por consequência os créditos não-performados desses créditos são explicados diante de quatro hipóteses de acordo com Berger e DeYoung (1997):

- “má sorte” da instituição: eventos exógenos que podem causar o aumento dos créditos inadimplidos;
- má administração: empréstimos sem bons critérios de avaliação e ausência de monitoramento dos empréstimos atrasados;
- descuido: os bancos podem atingir baixos custos através de subutilização de subscrição de empréstimos e monitoramento no curto prazo e ao longo do tempo isso resulta em aumento dos créditos problemáticos; e
- risco moral: tendência à aceitação de riscos devido ao fato dos custos não serão incorridos sobre a parte que está aceitando correr o risco.

A partir da aquisição dessas dívidas por parte dos FIDCs, devem ser definidas estratégias para a sua recuperação. Um modelo de estratégia de recuperação e estruturação de um portfólio de NPLs foi proposto pelo International Finance Corporation (2012).

Em McNelis (2005) é apresentado um método de construção de estratégia para reestruturação desses créditos de forma em que são levados aspectos endógenos relativos aos créditos não-performados, como a revisão do portfólio e determinação de atributos desses ativos; como também aspectos exógenos ligados ao ambiente econômico no qual essa estruturação de estratégia é realizada. Com esse tipo de avaliação são construídas estratégias para a recuperação e reestruturação desses créditos.

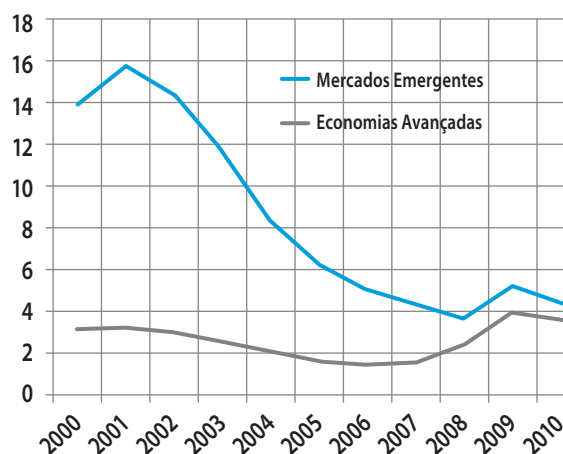
No estudo sobre o capital econômico empregado em previsões de portfólios de NPLs, Weißbach e Wilkau (2008) afirmam que o risco desses tipos de portfólios juntamente com os portfólios de créditos adimplidos depende da volatilidade da atividade econômica sobre a granularidade do portfólio e sobre o portfólio performado.

O estudo relativo à constituição de créditos não-performados está relacionado com a questão de governança bancária cujos ativos relativos a empréstimos bancários ocorrem em perdas bancárias devido ao *insider lending*, que são empréstimos facilitados devido mais a questões subjetivas do que de caráter objetivas (BONIN *et al.*, 2008).

Um trabalho sobre a cointegração de métodos de avaliação desses portfólios de créditos inadimplidos é exposto por Toledo (2013), cujo estudo evidencia o panorama no aspecto macro econômico dentro do mercado brasileiro, bem como um modelo de precificação relativo às dinâmicas do mercado brasileiro em NPLs.

No trabalho de Vogiazas e Nikolaidou (2011) os autores realizam a ligação entre aspectos macroeconômicos e as dinâmicas do mercado financeiro com as dinâmicas em caráter qualitativas dos ativos NPLs na Grécia. O estudo apresenta uma forte relação entre índices de desemprego, atividade industrial, e a taxa de câmbio. A Figura 1 apresenta a evolução do índice de crescimento dos NPLs ao longo do tempo em economias de mercados emergentes e economias em maior estado de desenvolvimento.

Figura 1 – Crescimento do índice de Créditos Inadimplidos (%). No eixo lateral esquerdo o volume em bilhões de dólares e abaixo o ano do estudo.



Fonte: Adaptada de European Central Bank, 2013.

Conforme a Figura 1, na curva azul representada pelos os mercados emergentes após a crise de 2008 houve um crescimento forte em relação à porcentagem de NPLs com uma queda no ano de 2009 da mesma intensidade. Já na curva cinza representada pelos mercados considerados avançados o crescimento dos NPLs começou em meados de 2006 e têm apresentado um volume de crescimento expressivo nos anos posteriores tendo uma queda significativa em 2009.

No artigo seminal recente do European Central Bank (2013) foi constatado que as dinâmicas dos NPLs obedecem as determinantes empíricas como crescimento do Produto Interno Bruto, índices de preços, taxas de câmbio, e a taxa de juros sobre os empréstimos.


No estudo em desenvolvimento pelo International Monetary Fund (2013) foi apresentado o desenvolvimento dos NPLs em países de diferentes regiões da Europa e revelou que os motivos do aumento se devem a condições macro econômicas e fatores específicos dos bancos como má administração, custos de performance, risco moral e excesso de empréstimos.

2.2. MULTILAYER PERCEPTRON (MLP)

As Redes Neurais Artificiais (RNAs) são modelos computacionais distribuídos compostos de unidades de processamento densamente conectadas e realizam atividades de otimização de uma função objetivo em relação a tarefas de aprendizado (FACELI, 2011).

As RNAs estão sendo usadas em diversos estudos devido ao seu poder de modelagem sobre dinâmicas de dados que possuem comportamento de natureza não linear, e também pelo seu poder de acurácia relativa à predição e classificação não linear (HAYKIN, 1994). As MLPs são organizadas em camadas de processamento paralelo como pode ser visualizado na Figura 2 (SALATAS, 2011).

Figura 2 – Arquitetura de uma MLP com camada de entrada (A), camadas escondidas (B, C) e camada de saída (D).



Fonte: Salatas, 2011.

O processo de aprendizado da MLP consiste na apresentação do conjunto de dados de treinamento, e na medida em que haja erros de classificação os pesos são ajustados e voltam de forma iterativa influenciando nos pesos sinápticos, a fim de minimizar os erros nas próximas iterações.

O método de aprendizado na MLP é o de retropropagação (ou retropropagação de erros - *backpropagation*) criado por Werbos (1974), que consiste em executar dois passos relativos ao método de treinamento, um passo para frente para formulação do resultado e a propagação reversa para com os erros obtidos na classificação ou regressão para ajuste dos pesos sinápticos.

O pseudocódigo algoritmo do *backpropagation* é descrito no Quadro 1.

Quadro 1 - Algoritmo de Treinamento do *Backpropagation*.

1	Inicialização dos Pesos de Forma Randômica
2	Repita
3	Repita Época
4	Escolha uma instância do conjunto de treinamento
5	Aplique a instância na rede
6	Avalie a saída da rede
7	Compare o valor da saída da rede com o valor desejado
8	Realize a ponderação dos pesos até a escolha de todas as instâncias do conjunto de treinamento
10	Até que o erro global < critério

Fonte: Adaptado de Drchal, 2012.

A ideia geral é que a RNA aprenda, conforme ocorre a minimização do erro, ou seja, quanto menor o erro, maior é o ajuste dos dados do modelo. Sendo assim, unindo as características de processamento distribuído e síncrono, com o aprendizado baseado na minimização do erro a abordagem com MLP torna-se uma boa alternativa para problemas de generalização de classificação de bases de dados.

3. METODOLOGIA EXPERIMENTAL

Para os experimentos e consequentes procedimentos relativos à geração das RNAs do tipo MLP foram criados cinco modelos com parâmetros diferentes para verificar se há diferenças significativas em relação parametrização destes modelos e a respectiva influência no resultado final.

Para a parametrização das redes neurais artificiais foram utilizados os seguintes valores para os cinco modelos:

- Taxa de Aprendizado: 0,7
- Momentum: 0,7
- Quantidade de Épocas: 5000
- Algoritmo: *Backpropagation*

Foram desenvolvidos cinco modelos e as suas respectivas parametrizações estão descritas na Tabela 1.

Tabela 1 – Parâmetros das redes dos experimentos.

Arquitetura das Redes					
	(#) Variáveis de Entrada	Amostragem	# Camada Escondida 1	# Camada Escondida 2	(#) Var. Saída
M1	10	Treino 70 - Teste 20 – Val 10	6	----	2
M2	10	Treino 70 - Teste 20 – Val 10	10	----	2
M3	10	Treino 70 - Teste 20 – Val 10	2	----	2
M4	10	Treino 70 - Teste 20 – Val 10	10	5	2
M5	10	Treino 70 - Teste 20 – Val 10	12	5	2

Fonte: Autores.

Nos modelos M1, M2, e M3 foi utilizada apenas uma camada escondida para treinamento e para teste com modificações no número de neurônios. Nos modelos M4 e M5 foram utilizadas duas camadas escondidas; na primeira camada escondida há variação do número de neurônios e na segunda camada escondida o número de neurônios permaneceu constante.

Essas diferenciações paramétricas têm como objetivo experimentar a influência das camadas e na variação de seus neurônios nos resultados dos modelos seja no aspecto no percentual de acertos da classificação, bem como na minimização dos erros que implicam em maiores custos em aspectos econômicos. A representação gráfica de um dos modelos do experimento é apresentada na Figura 4.

Para processamento das informações foi utilizado o *software* WEKA da Universidade de Waikato em um computador Samsung modelo RV415 com 4Gb de processamento e 4Gb de memória RAM. Foi realizado pré-processamento dos dados para discretização dos dados numéricos convertendo todos os campos para algarismos binários e foi utilizada a validação cruzada (*cross-validation*) com particionamento no fator 10 ($k\text{-fold} = 10$).

3.1. Base de Dados

A base de dados consiste em 19.845 registros relativos a cartões de crédito e empréstimos para pequenas e médias empresas já vencidos e não-performados. Como tratam-se de dados reais, para a proteção da confidencialidade os nomes de alguns atributos foram modificados e informações relativas aos clientes foram eliminadas da base. A relação de atributos utilizados na amostra dos créditos está apresentada no Quadro 2.

Quadro 2 – Relação de atributos na base de dados.

Variável	Atributo	Tipo
1	IDContrato	Numérico
2	Saldo	Monetário
3	IDCliente	Numérico
4	Saldo Atual	Monetário
5	IdadeDivida	Numérico
6	TipoCrédito	Nominal
7	MêsAberturaContrato	Data
8	AnoAbertura	Data
9	Estado	Nominal
10	TipoProduto	Nominal
11	CanaldeContato	Nominal
12	CanaldeLocalizacao	Nominal
13	NegativadoBureauCrédito	Binário
14	Pago	Binário

Fonte: Autores.

As distribuições relativas aos saldos e a quantidade de créditos recuperados estão dispostas nas Tabelas 2 e 3.

Tabela 2 – Distribuições relativas aos *status* de recuperação.

<i>Status</i>	Saldo Total	# Contratos	% Total (Saldo)	% Total (Contratos)
Não Recuperado	\$ 10,606,307.06	7,287	39.29%	36.72%
Recuperado	\$ 16,388,598.74	12,558	60.71%	63.28%
<i>Grand Total</i>	\$ 26,994,905.80	19,845	100.00%	100.00%

Fonte: Autores.

Na Tabela 3, é apresentada a distribuição dos créditos dentro do portfólio de acordo com o tipo de produto que teve a perda bancária.

Tabela 3 – Distribuição relativa aos tipos de produtos no portfólio


Tipo de Crédito	Saldo Total	# Contratos	# Contratos Pagos
Cartão de Crédito	26,381,342.60	19,741	12,509
SME	613,563.20	104	49
Grand Total	26,994,905.80	19,845	12,558

Fonte: Autores.

Uma característica importante relativa aos créditos NPLs é a idade média da dívida, na qual uma dívida com uma idade maior geralmente apresenta um potencial menor de recuperação. Isso obriga os gestores de FIDCs a considerarem o tempo relativo à essas dívidas em seus modelos de precificação bem como administração do risco inerente à aquisição de uma dívida com baixa possibilidade de recuperação (INTERNATIONAL FINANCE CORPORATION, 2012).

Nas Figuras 3 e 4 são apresentadas as evoluções temporais de dívidas de cartões de crédito e de pequenas e médias empresas no portfólio estudado.


Figura 3 – Distribuição temporal e evolução dos NPL relativos a cartões de crédito ao longo do tempo.



Fonte: Autores.

Na Figura 3 verifica-se que o maior volume financeiro está concentrado entre os anos de 2006 e 2010; o que mostra que dívidas de cartões de crédito, obedecem a um grau de recência considerável tratando-se de potencial de recuperação.

Figura 4 – Distribuição temporal e evolução dos NPL em milhões de reais relativos a pequenas e médias empresas (*Small and Medium Enterprises – SME*) ao longo do tempo



Fonte: Autores.

Já a Figura 4 apresenta a estrutura dos NPLs neste portfólio relativa às pequenas e médias empresas; indica uma determinada dinâmica cíclica, mas também com um crescimento em sua recência, a partir do ano de 2005.

5. RESULTADOS EXPERIMENTAIS

Os experimentos foram realizados para avaliar o desempenho das redes através do ajuste paramétrico de cada uma delas, e o seu comportamento através da modificação desses parâmetros. Além disso, comparamos as redes dentro das métricas de avaliação de classificadores, e também os custos econômicos envolvidos apresentados pelas redes.

Primeiramente realizamos a comparação das redes através das métricas de classificadores disponíveis no WEKA. A Tabela 4 apresenta o resultado da validação dos modelos da MLP na classificação dos créditos.

Tabela 4 – Resultados dos experimentos: validação da rede.

Tabela de Desempenho										
	%Erro C-Positiva	%Erro C-Negativa	%Erro	%Acurácia	%Precisão	%Sensibilidade	%Especificidade	Acertos	Erros	Kappa
M1	21.84%	9.28%	14.24%	85.76%	84.60%	78.16%	90.72%	4,595	763	0.6980
M2	21.31%	9.81%	14.26%	85.74%	83.52%	78.69%	90.19%	4,594	764	0.6963
M3	22.51%	8.78%	14.32%	85.68%	85.62%	77.49%	91.22%	4,591	767	0.6978
M4	22.35%	8.63%	14.17%	85.83%	85.88%	77.65%	91.37%	4,599	759	0.7010
M5	20.61%	9.72%	13.90%	86.10%	83.57%	79.39%	90.28%	4,613	745	0.7033

Fonte: Autores.

Para avaliar a classificação dos modelos experimentais, também foi adotada a matriz de confusão que informa os valores previstos em relação aos valores atuais após a classificação (KOHAVI; PROVOST, 2011).

Para avaliação dos modelos de classificação, foi criada uma estrutura de custos econômicos, que consta na Tabela 5, determinando parâmetros de acordo com um custo relativo de sucesso ou erro de classificação em uma abordagem relativa à cobrança de uma dívida. Isto significa que os custos relativos a uma operação de recuperação desses ativos podem variar de acordo com os custos diretos da instituição como, por exemplo, campanhas de cartas para os devedores, comunicação telefônica, custo de operadores em um *Call Center*, custo dos negociadores, telefonia, espaço físico, entre outros.

Tabela 5– Tabela de Custos.

Parâmetros de Custos		
Custo/Benefício do Modelo	TP – Verdadeiros Positivos	- 1
	FP – Falsos Positivos	9
	FN – Falsos Negativos	4
	TN – Verdadeiros Negativos	- 2

Fonte: Autores.

Uma proposta empírica de tratamento dos custos envolvidos em recuperação de créditos NPL é apresentada no trabalho de Toledo (2013) no qual foi proposto um modelo de fluxo de recuperação líquida em que um dos parâmetros utilizados é um vetor de custo mensal que considera os atributos citados anteriormente, conforme a Equação 1.

$$c_{1xn}^* = \rho^* \mu_{1xn}^* \quad (1)$$

Na qual:

c_{1xn}^* = vetor de custo mensal; e

ρ = custo médio operacional por negociador por mês.

Com isso o modelo de fluxo de recuperação é definido, conforme a Equação 2.

$$\lambda_{1xn}^* = \psi_{1xn}^* - c_{1xn}^* \quad (2)$$

Onde:

(ψ_{1xn}^*) = Vetor de recuperação; e

(c_{1xn}^*) = Vetor de custos estimados.

Dessa forma, como a estrutura de custos é aplicada de forma empírica, serão usadas métricas de classificação com pesos artificiais para não somente validar o resultado das classificações, como também verificar o custo econômico de cada modelo, devido à natureza financeira do estudo. Dessa forma, os pesos relativos às nossas classificações são considerados:

- TP (Verdadeiros Positivos) – Dívidas com alto potencial de recuperação classificadas corretamente, neste caso o custo econômico que bonifica o modelo é uma economia em termos de custo de -1 unidade monetária;
- FP (Falsos Positivos) – Dívidas com baixo potencial de recuperação classificadas incorretamente, neste caso o custo econômico que penaliza o modelo é 9 unidades monetárias;
- FN (Falsos Negativos) – Dívidas com alto potencial de recuperação classificadas incorretamente, neste caso o custo econômico que penaliza o modelo é 4 unidades monetárias;
- TN (Verdadeiros Negativos) - Dívidas com baixo potencial de recuperação classificadas corretamente, neste caso o custo econômico que bonifica o modelo é -2 unidades monetárias.

Com os parâmetros estabelecidos, os resultados para cada modelo em termos de custos econômicos estão escritos na Tabela 6.

Tabela 6 – Tabela de Custos dos Modelos.

	Custos do Modelo				
	TP	FP	FN	TN	Custo do Modelo
Modelo 1	1,653	301	462	2,942	5,844
Modelo 2	1,632	322	442	2,962	18,054
Modelo 3	1,673	281	486	2,918	9,048
Modelo 4	1,678	276	483	2,921	(435)
Modelo 5	1,633	321	424	2,980	2,980

Fonte: Autores.

5.1. Análise e Discussão dos Resultados

No experimento do modelo 1 verificou-se que a taxa de acertos foi a 2ª maior (4,595). Contudo, o índice Kappa apresentou o pior desempenho e o seu custo econômico foi o 3º maior (5,844). Com estes resultados o modelo 1 apresentou um resultado intermediário entre todos os modelos envolvidos nos experimentos.

No segundo experimento o modelo 2 teve como principal característica o maior custo econômico em unidades monetárias (18,054) dentre todos os modelos. Isso pode ser explicado devido à alta penalização da MLP em termos de falsos positivos (322) e a alta porcentagem de erros na classe negativa (9,81%). Mesmo com a 2ª maior acurácia (85,74 %) a sua precisão apresentou o pior desempenho.

Isso possibilita ver que erros na classe negativa são fatores determinantes no mau desempenho desse modelo levando a induzir que, antes de acertar a melhor dívida para ser cobrada é preciso minimizar erros decorrentes de má classificação, que são mais custosos.

No experimento do modelo 3 foi apresentado o maior erro relativo à classe positiva (22,51%) e o segundo menor erro na classe negativa (8,78%). Mesmo com o maior índice de erros (14,32%) o custo econômico ficou em 2º lugar, tendo o pior desempenho (9,048). Este modelo apresentou também a menor sensibilidade, isto é, a menor capacidade de identificar resultados positivos.

Com muitos erros na classificação negativa, este modelo teve um desempenho ruim em relação aos experimentos realizados devido à baixa generalização na classificação de dívidas com potencial de recuperação.

O experimento do modelo 4 apresentou o melhor custo (-435) mesmo com o segundo maior erro na classe positiva (22,35%). Outro fato é que esse modelo teve o menor erro na classe negativa (8,63%) e a maior precisão (85,88 %).

O melhor resultado obtido nos experimentos por esse modelo explica-se pela baixa penalização do classificador devido ao baixo índice de erros, e a precisão nos acertos da classe negativa. Isso possibilita ver que além de minimizar custos relativos a erros de falsos positivos, os acertos relativos aos créditos ruins são determinantes em termos de custos; o que leva a crer que este é o melhor modelo por induzir uma situação de minimização de custos.

Finalmente, no experimento do modelo 5, foi apresentado o melhor índice de Kappa (0,7033), que indica que a classificação foi satisfatória, e também o menor erro na classe positiva (20,61%) e o menor erro no geral (13,90%). Este modelo também teve a maior sensibilidade (79,39%), o que indica a sua boa capacidade de identificar casos da classe positiva.

Pode-se concluir com os resultados desse modelo que mesmo com as melhores classificações por época, e a melhor capacidade de identificação de positivos; os erros que implicam em penalizações em termos de custos econômicos são fator fundamental no desempenho desse modelo, pois, além de considerarem os acertos inerentes da classificação, utilizam a estrutura de penalização econômica de acordo como tipo de erro cometido na atividade de classificação.

6. CONSIDERAÇÕES FINAIS

Com a crescente evolução dos produtos bancários os créditos não-performados tornaram-se uma alternativa de investimento que tem como características o seu alto volume de transações em bases de dados.

Uma MLP foi usada na criação de modelos para classificação de portfólio de NPLs. Os modelos apresentaram de um modo geral resultado satisfatório em termos de generalização da classificação.

Os resultados obtidos confirmam que o modelo 4 apresentou o melhor desempenho por meio do balanceamento do número de neurônios em duas camadas escondidas (10 neurônios na primeira camada e 5 neurônios na segunda camada), o que o coloca como o melhor modelo dentre os cinco na classificação de créditos NPL.

Conclui-se então que a MLP pode ser considerada uma importante ferramenta na análise e classificação em bases de dados heterogêneas, como a de créditos não-performados, sendo capaz de criar um modelo de generalização robusto para análises prévias. Como proposta para trabalhos futuros esta pesquisa será continuada em termos a se elaborar estratégias relativas à recuperação desses créditos realizando a geração de filas de cobrança de acordo com as características dos créditos pagos.

REFERÊNCIAS

BERGER, A. N.; DEYOUNG R. Problem Loans and Cost Efficiency in Commercial Banks. **Journal of Banking and Finance**. n. 21,p. 849-870, 1997.

BERGER, J. O. **Statistical Decision Theory and Bayesian Analysis**. Berlin: Springer-Verlag, 1985.

BONIN, J.; HASAN, I.; WACHTEL P. Banking in transition countries. **BOFIT Discussion Paper**, 12. 2008.

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification and regression trees**. Wadsworth & Brooks/Cole Advanced Books & Software, 1984.

DRCHAL, J. **Artificial Neural Networks: MLP, Backpropagation**. Computational Intelligence Group. 2012. Disponível em: <<http://cw.felk.cvut.cz/lib/exe/fetch.php/courses/a4m33bia/a4m-33bia-03backprop-2012.pdf>> Acesso em: 13 abr. 13.

EUROPEAN CENTRAL BANK. Non-Performing Loans: What matters in addition to the economic cycle? **Working Paper Series**. n. 1515, 2013.

FACELI, K. et al. **Inteligência Artificial: uma abordagem de aprendizado de Máquina**. Rio de Janeiro: Editora LTC, 2011.

HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. New York: The Morgan Kaufmann Series in Data Management. Morgan Kaufmann, 2000.

HARREL, F. **Regression Modeling Strategies: With Applications to Linear Models, Logistic Regression, and Survival Analysis**. New York: Springer Series in Statistics, Springer. 2001.

HAYKIN, S. **Neural Networks: A comprehensive Foundation**. New York: Wiley & Sons, 1994.

HERRERIAS, R.; MORENO, J. O. **Spillovers and Long-Run Diffusion of Non-Performing Loans Risk**. Working Paper. Departamento de Administración do México. Disponível em: <<http://departamentodeadministracion.itam.mx/workingpapers/Spillovers%20and%20Long%20Run%20Diffusion%20of%20NPLs.pdf>> Acesso em: 05 abr. 13.

INTERNATIONAL FINANCE CORPORATION. **NPL and Risk Management in ECA**. 2012.

INTERNATIONAL MONETARY FUND. **Non-Performing Loans in CESEE: Determinants and Impact on Macroeconomic Performance**. Nir KLEIN. IMF Working Paper WP/13/72, 2013.

KOHAVI, R.; PROVOST, F. Special Issue on Applications of Data Mining to Electronic Commerce. **Data Mining and Knowledge Discovery**, 5, 2011.

MCNELIS, P. D. **Neural Networks in Finance: Gaining Predictive Edge in the Market**. Academic Press Advanced Finance. Academic Press. 2005.

QUINLAN, J. R. **Induction of Decision Trees**. New York: Machine Learning, Kluwer Academic Publishers, 1986.

SALATAS, J. **Implementation of Elman Recurrent Neural Network in WEKA**. 2011. Disponível em: <jsalatas.ictpro.gr/implementation-of-elman-recurrent-neural-network-in-weka/> Acesso em: 05 abr. 13.

TOLEDO, R. P. P. **Mercado brasileiro de non-performing loans (NPL): uma abordagem teórica e prática na precificação de ativos**. São Paulo: FGV, 2013. 54 p. Dissertação (Mestrado) – Escola de Economia de São Paulo, Fundação Getulio Vargas, São Paulo, 2013.

VOGIAZAS, S. D.; NIKOLAIDOU, E. **Credit risk determinants in the Bulgarian banking system and the Greek twin crises**. MIBES, 2011.

WEIßBACH, R.; WILKAU, C. L. **Capital for Non-Performing Loans**. 2008.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral science**. Cambridge: Harvard, 1974. Tese (Doutorado). Harvard University, Cambridge, 1974.