

PREVISÃO DE INADIMPLÊNCIA EM UMA INSTITUIÇÃO DE ENSINO SUPERIOR BASEADA EM REDES NEURAS ARTIFICIAIS

Daniel de Oliveira Capanema

Graduado em Ciência da Computação, Especialista em Desenvolvimento de Sistemas para *Web*, Mestrando em Modelagem Matemática Computacional. PPGMMC-CEFET-MG, danielcapanema@hotmail.com

João Paulo Barbosa Nascimento

Graduado em Sistemas da Informação, Mestre em Modelagem Matemática Computacional, Doutorando em Modelagem Matemática Computacional. PPGMMC-CEFET-MG, joaopaulobn2@gmail.com

Resumo

O problema da inadimplência é algo comum e que a cada dia se torna mais corriqueiro no cotidiano das instituições privadas de ensino superior no Brasil e diversos fatores podem motivá-la, tais como o aumento da taxa de desemprego e do índice de inflação. As instituições privadas de ensino superior no Brasil são responsáveis por 86 por cento no total de matrículas dos cursos de graduação e o percentual de inadimplência nessas instituições pode chegar a 12 por cento. As Redes Neurais Artificiais (RNAs) são um conjunto de técnicas que tentam simular, em meio computacional, o funcionamento do cérebro humano. Elas são capazes de reconhecer padrões, extrair regularidades e detectar relações subjacentes em um conjunto de dados aparentemente desconexos. O objetivo principal deste trabalho é apresentar uma aplicação baseada em Redes Neurais Artificiais que possa auxiliar os gestores de escolas de ensino superior na tomada de decisão acerca da inadimplência de seus alunos. Para isso, foram coletados dados referentes aos pagamentos de mensalidades realizados por alunos de uma instituição de médio porte em determinado período de tempo e realizado experimentos criando uma Rede Neural MLP, avançando para a implementação de uma rede RBF e finalizamos os experimentos com uma Rede Neuro-fuzzy ANFIS. Este trabalho contribuiu com uma solução computacionalmente inteligente para o problema da previsão de inadimplência de alunos do ensino superior de instituições particulares.

Palavras-chave: ANFIS. MLP. RBF. Redes Neurais.

Abstract

The problem of default is common and that every day becomes more commonplace in the daily lives of private institutions of higher education Brazil and several factors may motivate them, such as the increase in the unemployment rate and the inflation rate. Private institutions of higher education Brazil account for 86 percent of total enrollment courses graduation and the percentage of defaults in these institutions can reach 12 percent. The Artificial Neural Networks (ANN) are a set of techniques that are trying to simulate in a computer environment, the operation of the human brain. They are able to recognize patterns, extract and detect regularities underlying relationships in a set of seemingly unrelated data. The main objective of this work is to present a based application Artificial Neural Networks that can assist managers of schools top decision-making about the default of their students. To Therefore, data were collected regarding those made monthly payments by students of a medium-sized institution in a given period time and conducted experiments creating a neural network MLP, advancing for the implementation of a RBF network and finalized the experiments with one Neuro-fuzzy Network ANFIS. This work contributed with a

solution computationally smart to the problem of predicting default of higher education students in private institutions.

Keywords: ANFIS. MLP. Neural Networks. RBF.

1. INTRODUÇÃO

O problema da inadimplência é algo comum e que a cada dia se torna mais corriqueiro no cotidiano das instituições privadas de ensino superior no Brasil e pode variar de instituição para instituição, porém todas desejam reduzir drasticamente este índice.

Diversos fatores podem motivar a inadimplência, tais como o aumento da taxa de desemprego e do índice de inflação, fatos estes que estamos presenciando nos últimos meses. Como exemplo, no mês de maio do ano corrente, o IPCA (Índice Nacional de Preços ao Consumidor Amplo) fechou em 0,99 por cento, porém, no mesmo mês do ano de 2010, esse mesmo índice fechou em 0,43 por cento. (IBGE, 2015).

As instituições privadas de ensino superior tem uma participação de aproximadamente 86 por cento do mercado de educação superior no país. Como estas instituições ocupam grande parte da fatia de mercado, torna-se necessário investir em ferramentas que possam criar estratégias para previsão de inadimplência para que a gestão destas empresas não fique comprometida, com isto evitando também um outro grande problema: a evasão escolar.

Para que o planejamento estratégico destas instituições possa ser cada vez mais efetivo e acertado, surge a necessidade de ferramentas automatizadas que forneçam aos gestores uma previsão mais acertada possível acerca da inadimplência em um dado período de tempo futuro. Esse período pode ser de um mês para um planejamento de curto prazo (operacional), de um semestre para um planejamento de médio prazo (tático) ou de um ano para um planejamento de longo prazo (estratégico). (CHIAVENATO, 2011).

Essas previsões, quando apresentadas com uma taxa de erro baixa, podem significar economia para as instituições, pois, quando se conhece a receita previamente os gastos podem ser melhor mensurados e os empréstimos e antecipações de recebíveis de emergência podem ser evitados ou melhor negociados.

Diante dessa necessidade surge a oportunidade de aplicação de tecnologias computacionais que, baseadas no comportamento e características de adimplência ou inadimplência dos alunos, possa prever qual será a possibilidade destes alunos atrasarem ou adiantarem seus pagamentos no próximo mês. As Redes Neurais Artificiais são uma tecnologia que podem fornecer resultados de previsões que auxiliem esses gestores em suas tomadas de decisões.

1.1. Objetivos

O objetivo principal deste trabalho é apresentar uma aplicação baseada em Redes Neurais Artificiais que possa auxiliar os gestores de instituições de ensino superior na tomada de decisão acerca da inadimplência de seus alunos matriculados e promover o melhor gerenciamento da carteira de recebíveis da instituição reduzindo a possibilidade de inadimplência por meio da identificação dos possíveis bons e maus pagadores e, com isto, contribuir para o incremento da lucratividade da instituição, diminuindo as possíveis perdas financeiras. Para isso, serão trabalhados os seguintes objetivos específicos:

- a) desenvolver uma Rede Neural básica;
- b) realizar experimentos com dados reais de uma instituição de nível superior;
- c) apresentar e analisar os resultados obtidos.

1.2. Organização do Trabalho

Este trabalho está organizado da seguinte forma: o capítulo 2 apresenta uma revisão bibliográfica com os principais assuntos aqui tratados. O capítulo seguinte (3) apresenta como os experimentos aqui tratados foram planejados e também a metodologia utilizada na condução desses experimentos. O capítulo 4 descreve detalhadamente os resultados alcançados e, em seguida, são apresentadas as conclusões, as considerações finais e as referências bibliográficas.

2. REVISÃO DA LITERATURA

O capítulo de revisão da literatura apresenta uma breve discussão acerca dos principais assuntos abordados no trabalho. A seção 2.1 faz uma abordagem de alguns conceitos essenciais de Redes Neurais Artificiais. Em seguida, na seção 2.2, é apresentada a Rede Neural MLP (*Multilayer Perceptron*). A seção 2.3 discute o funcionamento das redes de base radial RBF e a seção seguinte (2.4) apresenta o funcionamento da rede Neuro-Fuzzy ANFIS. O capítulo é encerrado com uma discussão sobre o aprendizado das redes neurais e com um panorama sobre as instituições de ensino superior no Brasil (seção 2.6).

2.1. Redes Neurais Artificiais

O cérebro de um ser humano é constituído por bilhões de neurônios e um neurônio caracteriza-se como uma célula formada por três funções específicas e complementares: corpo, dendritos e axônio. Os dendritos capturam os estímulos recebidos em determinado período de tempo e os transmitem ao corpo do neurônio. No momento que os estímulos atingirem um limite determinado, o corpo da célula envia um novo impulso que irá se propagar pelo axônio e será transmitido às células vizinhas por meio de outra função que são as sinapses. O processo descrito poderá ser repetido por diversas camadas de neurônios e como resultado, a informação de entrada será processada, podendo obter como resultado a condução do cérebro a comandar reações físicas. A Fig. 1 ilustra a divisão de um neurônio de forma simplificada. (HAYKIN, 2001).

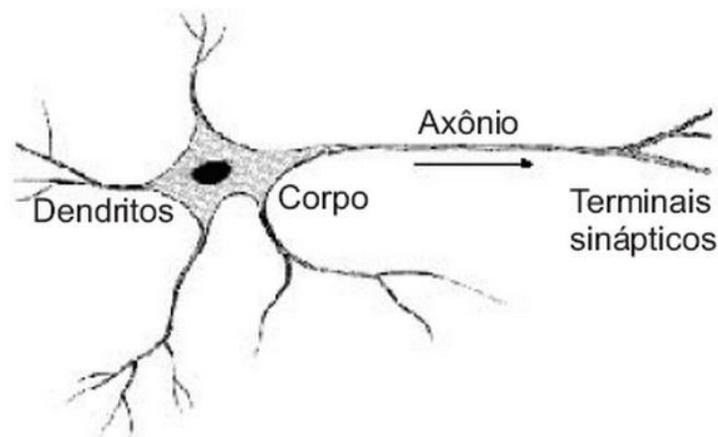


Figura 1. Representação simplificada de um neurônio

Fonte: HAYKIN, 2001.

A habilidade que um ser humano tem de realizar funções complexas e de aprender, surge da forma com que o seu cérebro realiza o processamento, ou seja, de forma paralela e distribuída. Na camada externa do cérebro temos o córtex e os neurônios que lá estão como os responsáveis pelo processamento cognitivo. A partir de uma nova experiência pessoal ou mesmo de um novo conhecimento, podemos apresentar alterações estruturais em nosso cérebro. Tais alterações são efetivadas por meio de um reposicionamento das redes de neurônios e isso pode inibir ou mesmo reforçar algumas sinapses. (HAYKIN, 2001).

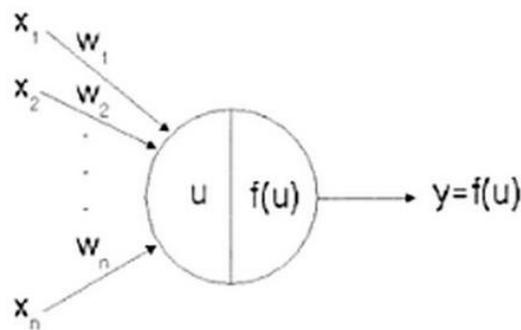
As Redes Neurais Artificiais (RNAs) são um conjunto de técnicas que tentam simular, em meio computacional, o funcionamento do cérebro humano. Elas são capazes de reconhecer padrões,

extrair regularidades e detectar relações subjacentes em um conjunto de dados aparentemente desconexos. Neste sentido, sua capacidade de prever sistemas não lineares torna possível a sua aplicação em problemas de previsão de inadimplência. (SANCHES; ZENI, 2013).

As Redes Neurais Artificiais (RNAs) são modelos matemáticos que se assemelham às estruturas neurais biológicas e que têm capacidade computacional adquirida por meio de aprendizado e generalização. O aprendizado em RNAs está normalmente associado à capacidade de as mesmas adaptarem os seus parâmetros como consequência de sua interação com o meio externo. Os critérios de desempenho que podem determinar a qualidade do modelo neural e o ponto de parada dos treinamentos são determinados por meio dos parâmetros utilizados no treinamento da rede neural. A generalização de uma rede está relacionada à capacidade que essa rede tem de promover respostas coerentes para dados utilizados como entrada em seu treinamento. (BRAGA, 2000).

As informações em RNAs são feitas através de estruturas neurais artificiais onde o processamento da informação é feito de forma paralela e distribuída. Cada elemento que realiza esse processamento é representado por uma estrutura denominada neurônio artificial. A Fig. 2 apresenta um esquema do neurônio artificial.

Figura 2. Visão esquemática de um neurônio artificial.



Fonte: REZENDE, 2003.

As entradas do neurônio artificial correspondem ao vetor de entrada denominado $X = [x_1, x_2, \dots, x_n]^T$ de dimensão n . Para cada uma das entradas x_i , há um peso correspondente w_i na entrada do neurônio. A soma dessas entradas x_i ponderadas pelos pesos correspondentes w_i é chamada de saída linear u , onde $u = \sum_i w_i x_i$. A saída y do neurônio é denominada saída de ativação e é obtida por meio da aplicação da função de ativação $f(\dots)$ à saída linear u , $y = f(u)$. A função de ativação $f(\dots)$ pode assumir várias formas geralmente não lineares. Um exemplo típico de função de ativação é a

função de grau unipolar, também chamada de limiar, aqui representada pela Fig. 3. O θ é o limiar do qual a saída do neurônio é ativada (REZENDE, 2003).

Figura 3. A função de ativação de um neurônio.

$$f(u) = \begin{cases} 0 & u < \theta \\ 1 & u \geq \theta \end{cases}$$

Fonte: REZENDE, 2003.

Uma Rede Neural artificial é, em suma, constituída por elementos processadores e cada elemento processador executa uma função relativamente simples porém, a Rede Neural Artificial, como um todo, tem capacidade computacional para a resolução de problemas complexos. (REZENDE, 2003).

2.2. Redes *Multilayer Perceptron*

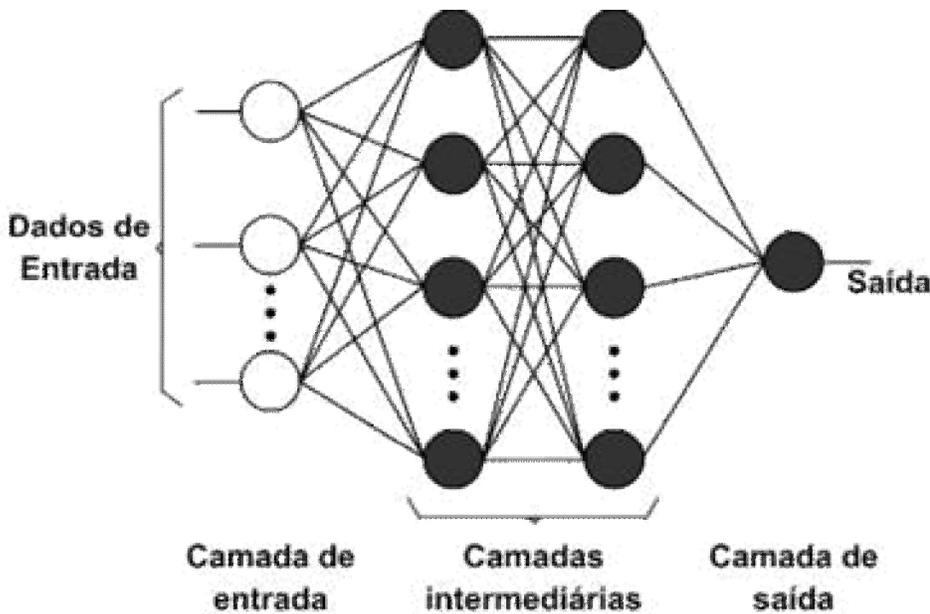
As redes de múltiplas camadas representam uma importante classe das Redes Neurais Artificiais. Basicamente, as MLPs consistem de um conjunto de unidades sensoriais (nós fonte) que representam a camada de entrada da rede. Além disso, essas redes possuem uma ou mais camadas de nós computacionais (camadas ocultas) e uma camada de saída. O sinal de entrada se propaga para frente dentro da rede, camada por camada. Essas redes representam uma generalização do *perceptron* de camada única. A Fig. 4 mostra o grafo arquitetural de um *perceptron* de múltiplas camadas com duas camadas ocultas e uma camada de saída, sendo dado como exemplo uma rede totalmente conectada. Isso significa que um neurônio em qualquer camada da rede está conectado a todos os outros neurônios da camada anterior. Assim, o sinal da rede avança de trás para frente (esquerda para direita) e de camada em camada. (HAYKIN, 2001).

As redes do tipo MLP (*Multilayer Perceptron*) possuem uma capacidade computacional maior do que as redes que não possuem camadas intermediárias, pois elas podem tratar dados que não são linearmente separáveis. (HAYKIN, 2001).

Os problemas não linearmente separáveis podem ser resolvidos por meio das redes com uma ou mais camadas ocultas. A alteração da arquitetura dessa rede, como a inclusão de mais neurônios ou de mais camadas ocultas, não parece ser um problema a princípio, pois o principal agravante passa a ser o algoritmo para treinamento. Essa questão causou uma queda na quantidade de pesquisas realizadas com MLPs na década de 1970. A determinação da quantidade de camadas a ser

utilizada pode influenciar drasticamente no aprendizado da rede. O uso de uma grande quantidade de camadas ocultas não é recomendado, visto que o erro ocorrido em uma camada é propagado a outras camadas da rede. A quantidade de neurônios que pertence a camadas ocultas é definido de forma empírica e normalmente depende da distribuição dos padrões de treinamento e validação da rede. Um uso excessivo de neurônios pode levar a rede a decorar o conjunto de treinamento, ao invés de atuar na generalização (extração de características gerais). Uma quantidade relativamente pequena de neurônios poderá levar a rede a aumentar o tempo de treinamento, e com isso dificultar a representação ótima do problema proposto. (BRAGA *et al.*, 2011).

Figura 4. Grafo arquitetural de um *perceptron* de múltiplas camadas com duas camadas ocultas.



Fonte: HAYKIN, 2001.

2.3. Redes de Função de Base Radial (RBF)

A Rede de base radial (RBF) (RUSSELL; NORVIG, 2003) é uma rede *feedforward*¹ multi-camadas cujos neurônios possuem como função de ativação uma função de base radial. Geralmente estas redes utilizam uma função gaussiana² (HAYKIN, 2001). Essas redes são comumente

1 A rede FeedForward é uma rede formada por camadas, onde cada camada se conecta à próxima sem realizar o caminho de volta, mantendo um sentido único. (HAYKIN, 2001).

2 Uma função Gaussiana é uma função na forma $f(x) = a \cdot e^{-\frac{(x-b)^2}{2c^2}}$, para alguns reais constantes a, b, c e $e \approx 2,71828$.

utilizadas em aproximação de funções, predição de séries temporais e controles de processos em geral.

As redes RBF e MLP se diferem principalmente pela função de transferência no interior da camada oculta, onde temos na MLP a tangente sigmóide³ e a gaussiana na RBF. A arquitetura da rede RBF, conforme apresentado na Fig. 5, tem como primeira camada vetores de entrada com dimensão m . A segunda camada corresponde a camada oculta (escondida), que é constituída por uma função de base radial. A camada de saída é uma combinação linear das funções radiais de saída dos neurônios da camada escondida.

A Rede Neural RBF apresenta, basicamente, dois estágios principais. No primeiro é efetuado a determinação dos parâmetros dos neurônios RBF, ou seja, os centros dos neurônios e a largura da função gaussiana. No segundo e último estágio, realiza-se o cálculo dos pesos entre a camada escondida e a camada de saída. (RUSSELL; NORVIG, 2003).

As redes de função de base radial (RBF) e os *perceptrons* de múltiplas camadas (MLP) são exemplos de redes em camadas alimentadas adiante, não-lineares. Ambos são aproximadores universais e, portanto, sempre existe uma rede RBF capaz de imitar precisamente um MLP específico, ou vice-versa. Essas duas redes diferem entre si em alguns aspectos importantes (HAYKIN, 2001):

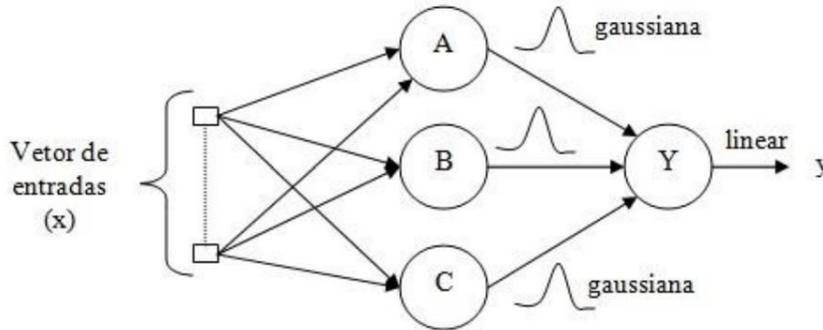
- a) uma RBF em sua forma básica tem apenas uma camada oculta, enquanto que um MLP pode ter uma ou mais camadas ocultas;
- b) os nós computacionais de uma MLP, em uma camada oculta ou de saída, compartilham um modelo neural comum. Em uma RBF os nós de uma camada oculta são diferentes e servem a um propósito diferente daqueles da camada de saída da rede;
- c) a camada oculta de uma RBF é não-linear, enquanto a camada de saída é linear. Entretanto, as camadas ocultas e de saída de um MLP, usado como classificador de padrões são normalmente todas não lineares.

A rede RBF difere do *perceptron* pela capacidade de implementar transformações não-lineares arbitrárias do espaço de entrada. Isso é bem ilustrado pelo problema do operador XOR⁴, que não pode ser resolvido por nenhum *perceptron* linear, mas que pode ser resolvido por uma rede RBF (HAYKIN, 2001).

³ Uma função Sigmóide é uma função na forma $f(x) = \frac{1}{1 + e^{-\lambda x}}$, para todo x real.

⁴ Operador lógico que retorna verdadeiro apenas quando os dois operandos possuem valores lógicos diferentes (MALVINO, 1985).

Figura 5. A arquitetura da rede RBF



Fonte: SILVA *et al.*, 2010.

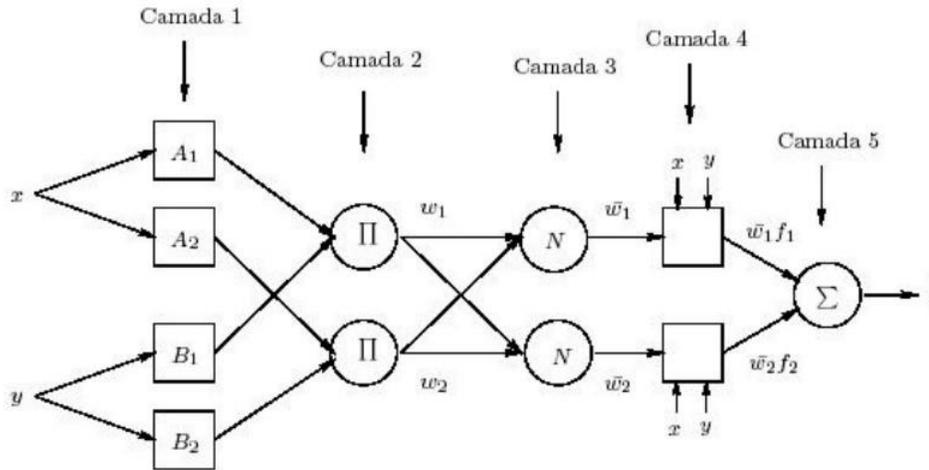
2.4. Redes Neuro-Fuzzy ANFIS

As redes Neuro-fuzzy (NF) são um popular arcabouço para auxílio na solução de problemas complexos. Se possuímos conhecimentos modelados por meio de regras linguísticas, podemos construir um Sistema Fuzzy de inferência e, se temos dados para serem processados e podemos gerar uma simulação (treinamento) com esses dados, podemos então utilizar uma Rede Neural Artificial. Para construir um Sistema Fuzzy de inferência, precisamos especificar os conjuntos Fuzzy, os operadores e toda a base de conhecimento. Similarmente para construir uma Rede Neural Artificial precisamos especificar a arquitetura e o algoritmo de treinamento. Uma análise revela que os inconvenientes referentes à estas abordagens parecem ser complementares uns aos outros e, diante dessa situação, torna-se natural considerar a construção de sistemas integrados e que combinam ambos os conceitos. Enquanto a capacidade de aprendizado é uma vantagem do ponto de vista das Redes Neurais Artificiais, a formação de uma base de regras linguísticas é a vantagem do ponto de vista de um Sistema Fuzzy de inferência (ABRAHAM, 2001).

O ANFIS (Adaptive Network-Based Fuzzy Inference System) consiste em uma rede adaptativa Neuro-Fuzzy com grande capacidade de aproximação, cuja arquitetura original foi desenvolvida por Jang (1993). Esse sistema tenta unir aspectos positivos de redes neurais e de sistemas de inferência nebuloso (Fuzzy). As Redes Neurais Artificiais são muito difundidas como ótimos aproximadores universais, porém deixam a desejar no que diz respeito à interpretação do processo de funcionamento da rede. Diante disso, os sistemas nebulosos tornam-se muito bons por

trabalharem com regras lógicas que tornam o sistema facilmente interpretável (USBERTI, 2007). A Fig. 6 apresenta a estrutura da arquitetura da rede ANFIS.

Figura 6. A arquitetura da rede ANFIS.



Fonte: JANG, 1993.

A primeira camada da rede é composta pelo grau de pertinência do padrão de entrada (x , y) e nesta camada calcula-se o grau de pertinência com que as entradas satisfazem os termos linguísticos associados a cada um desses nós. Na segunda camada, cada nó correspondente é associado a uma regra e nesta camada calcula-se o grau de ativação de cada regra. Na terceira camada é realizada a normalização, onde cada nó calcula a razão entre o nível de disparo da regra i pela soma dos níveis de disparo de todas as regras. Na quarta camada, as saídas do neurônio são calculadas pelo produto entre os níveis de disparo normalizados e o valor de consequente da regra i . Na última camada calcula-se a saída precisa. O sistema Neuro-Fuzzy ANFIS pode ser utilizado para solução de problemas de aproximação de função e identificação de sistemas (JANG, 1993).

2.5. Aprendizado

O aprendizado é definido por Mendel e McLaren (1994) como o processo pelo qual os parâmetros de uma rede neural são ajustados por meio de uma sequência ordenada de estímulos aplicados no ambiente ao qual a rede está sendo aplicada.

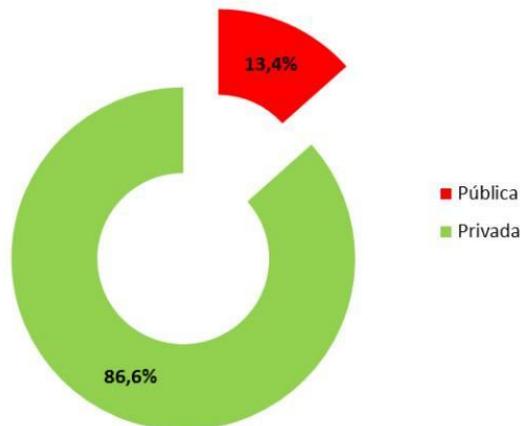
Por sua vez Braga (2000) discute que as Redes Neurais Artificiais têm a capacidade de aprendizado por meio de exemplos e também por meio de extrapolações e interpolações em cima do que elas aprenderam. O algoritmo de aprendizagem de uma determinada rede neural trata do conjunto de procedimentos definidos para adaptação dos parâmetros de uma RNA, para que a mesma tenha a capacidade de aprender uma função específica.

Atualmente é possível encontrar na literatura inúmeros métodos para treinamento de Redes Neurais Artificiais, sendo estes classificados como aprendizado supervisionado e aprendizado não-supervisionado.

2.6. Instituições de Ensino Superior

De acordo com o Censo da Educação Superior 2013 publicado pelo INEP (2013) o Brasil possui mais de 5,3 milhões de alunos matriculados em 2090 instituições privadas distribuídas em todo território nacional. Essas instituições possuíam, na data do estudo, 181302 docentes em exercício e uma participação de mais de 86 por cento no total de matrículas dos cursos de graduação, conforme apresentado na Fig. 7.

Figura 7. Percentual de matrículas em cursos de graduação em instituições privadas e públicas no Brasil.



Fonte: INEP, 2013.

Essas instituições faturaram no ano de 2013, aproximadamente 32 bilhões de reais somente com a modalidade graduação (presencial e EAD), um aumento de 11,90 por cento em relação ao ano anterior (2012), conforme demonstra o Tab. 1.

Tabela 1. Faturamento do setor educacional no Brasil

Segmento	2011 Faturamento Estimado (bilhões)	2012 Faturamento Estimado (bilhões)	2013 Faturamento Estimado (bilhões)
Graduação (Presencial + EaD)	R\$ 24,70	R\$ 28,23	R\$ 32,04
Pós Graduação (Presencial + EaD)	R\$ 3,74	R\$ 3,99	R\$ 4,19
Educação Básica	R\$ 32,43	R\$ 33,87	R\$ 39,16
Sistemas Apostilados de Ensino	R\$ 0,96	R\$ 1,20	R\$ 1,40
Livros Didáticos (PNLD + PNLEM)	R\$ 1,16	R\$ 1,09	R\$ 1,24
Livros Didáticos (sem participação de compra pelo governo)	R\$ 1,03	R\$ 1,75	R\$ 1,90
Total Geral	R\$ 64,02	R\$ 70,13	R\$ 79,93

Fonte: INEP, 2013.

Com o crescimento acentuado da quantidade de alunos matriculados nas instituições privadas brasileiras, surge a preocupação e a necessidade de uma gestão empresarial nessas empresas, principalmente para criar mecanismos de defesa contra a inadimplência dos alunos. A inadimplência gera prejuízos e transtornos às universidades e, portanto, deve-se identificar os motivos de seu surgimento, podendo em seguida traçar estratégias para se precaver dos problemas causados por ela (HERLING; MORITZ, 2013).

De acordo com o estudo realizado por Herling e Moritz (2013), o percentual de inadimplência nessas instituições privadas pode chegar a 12 por cento, conforme apresentado na Tab. 2.

Tabela 2. Comparação entre alunos matriculados e inadimplentes

Semestres	Total de Matrícula	Total de Inadimplência ao Final do Semestre Letivo	Percentual de Inadimplência
2008.2	8190	976	12%
2009.1	9794	1149	12%
2009.2	10688	1134	11%
2010/1	11.011	1054	10%
2010/2	11.215	504	4%

Fonte: HERLING; MORITZ, 2013.

O diferencial competitivo de uma empresa depende essencialmente de sua capacidade de desenvolver soluções para as demandas da sociedade. Essa capacidade surge dos conhecimentos e das experiências acumuladas ao longo do tempo por seus funcionários. Tal conhecimento do negócio, por não ser um produto concreto, corre o risco de ser perdido com mudanças no quadro de pessoal, oriundos de demissões e aposentadorias (REZENDE, 2003).

3. METODOLOGIA E PLANEJAMENTO DOS EXPERIMENTOS

Para a realização deste trabalho foram coletados dados referentes aos pagamentos de mensalidades realizados por alunos de uma instituição de médio porte em determinado período de tempo, localizada na região centro-oeste de Minas Gerais e com mais de 40 anos de fundação. A faculdade possui atualmente em torno de 1000 alunos e 13 cursos de graduação, além de cursos de pós-graduação e extensão. O escopo deste trabalho restringe-se apenas aos alunos dos cursos de graduação.

Diante do escopo descrito acima foi solicitado à instituição dados referentes aos períodos apresentados pela Tab. 3:

Tabela 3. Conjunto de dados utilizados nos experimentos.

Mês Inicial	Mês Final	Quantidade de alunos
01/2013	06/2013	973
07/2013	12/2013	1150
01/2014	06/2014	1050
07/2014	07/2014	1197
01/2015	05/2015	979

Fonte: Dados coletados pelos autores, 2015.

Após o recebimento dos dados, foi necessária a construção de um programa que fizesse a transformação desses dados em um formato matricial que pudesse ser lido pela ferramenta a ser construída. Além disso, descartou-se os dados referentes ao ano de 2015, pois esse ano não estava com nenhum semestre completo ainda.

Tanto os dados referentes aos semestres quanto os dados referentes aos anos foram embaralhados aleatoriamente e depois processados. Essa ação foi tomada para diminuir alguma possível influencia de algum mês ou ano nos resultados.

Para o processamento dos dados, iniciou-se os experimentos criando uma Rede Neural MLP, avançando para a implementação de uma rede RBF e finalizou-se os experimentos com uma Rede Neuro-fuzzy ANFIS. O objetivo é que as três redes apresentem algum tipo de resultado que possa ser comparado uns aos outros, culminando assim em uma rede neural que tenha uma capacidade satisfatória de trabalhar com uma área muito específica do mercado.

Diante das redes descritas no parágrafo anterior, foram realizados experimentos variando a quantidade de alguns parâmetros fundamentais de execução, tais como: número de neurônios e quantidade de épocas, e como saída das redes foram medidos a média, o máximo de erro e também o tempo gasto para treinar cada uma das redes. O erro médio é a média aritmética da soma de todos os erros, dividido pelo total de erros da rede. O erro máximo é o maior erro encontrado durante todo o processamento dos dados.

A ferramenta utilizada para implementação da solução foi desenvolvida utilizando o MathWorks Matlab em sua versão 7.11.0 (R2010b) 64 bits. O equipamento utilizado para a execução dos experimentos foi um computador com processador Core i3 64 bits com 4 gigabytes de memória RAM e Sistema Operacional Windows 7.

Faz-se importante destacar que utilizou-se 60 por cento da base de dados para treinar a Rede Neural e 40 por cento para testar os resultados.

Durante os primeiros experimentos, tentou-se utilizar as redes neurais para que estas pudessem prever a quantidade de dias que um determinado aluno iria atrasar ou adiantar o pagamento de sua mensalidade. Após alguns experimentos, verificou-se que essa estratégia era inviável do ponto de vista de resultados da rede, pois apenas o histórico de pagamentos não é suficiente para esta análise, uma vez que outros dados do aluno devem ser levados em conta, como idade, estado civil ou outros gastos mensais. Com isso, partiu-se para uma nova abordagem e criou-se um sistema de classificação, no qual a rede passou a ter como resultado um número de 1 até 10. Quanto mais baixo o valor retornado, melhor é o índice de adimplência de determinado aluno. Assim, pode-se dizer que o valor 1 é excelente (aluno paga antecipado), 5 é médio (às vezes atrasa o pagamento) e 10 é péssimo (frequentemente atrasa). Percebeu-se que esse sistema de classificação poderá auxiliar melhor o Analista de Crédito na tomada de decisões no momento de realizar o parcelamento de uma dívida, receber algum cheque do aluno ou mesmo realizar algum acordo financeiro.

Diante dos experimentos aqui planejados, será apresentado no Capítulo 4 os resultados alcançados e uma discussão sobre estes.

4. RESULTADOS

Este capítulo apresenta os resultados alcançados pelos experimentos, separados por seções específicas representando cada uma das redes utilizadas. A seção 4.1 apresenta os resultados da Rede Neural MLP, seguido pelas seções 4.2 e 4.3 que apresentam os resultados das Rede RBF e ANFIS, respectivamente. O capítulo é finalizado com as considerações finais e sugestões de trabalhos futuros.

4.1. Redes MLP

Os experimentos realizados com a rede MLP foram executados para os dados semestrais e para os dados anuais da faculdade alvo do estudo.

Para os dados semestrais foram utilizadas as funções de ativação *Tansig* e *Purelin* e diversos algoritmos de treinamento, a saber. Os algoritmos *Traingd*, *Traingdm* e *Traingda* apresentaram bons tempos de execução, porém os resultados apresentados foram muito ruins e, portanto, estes algoritmos foram descartados. O algoritmo *Trangdx* não chegou a concluir nenhum dos experimentos executados. Por fim, escolhemos o algoritmo *Trainlm* como padrão para os experimentos.

A quantidade de neurônios utilizadas nos experimentos com a Rede MLP começou em 5 e chegou até 80 unidades e, para o erro mínimo foram utilizados os valores 10^1 , 10^2 e 10^3 . O número de épocas⁵ foi empiricamente definido com valores de 1000, 2000 e 3000. A Tab. 4 apresenta os detalhes dos parâmetros utilizados e os resultados de tempo de treinamento e erro (médio e máximo alcançados).

Tabela 4. Resultados para os dados semestrais na rede M Fonte: Elaborada pelos autores.

Neurônios	Erro Mínimo	Épocas	Erro Médio	Erro Máximo	Tempo (segundos)
5	10^{-2}	1000	0.0133	1.6961	27
10	10^{-2}	1000	0.0084	0.3552	35
30	10^{-2}	1000	0.0143	0.8900	86
50	10^{-2}	1000	0.0030	0.3277	161
80	10^{-2}	1000	0.0188	0.9183	313
10	10^{-3}	1000	0.0096	0.8285	41
30	10^{-3}	1000	0.0126	0.6910	91
50	10^{-3}	1000	0.0129	1.2326	162
10	10^{-1}	1000	0.0068	0.4634	37
10	10^{-2}	2000	0.0034	0.2469	65
10	10^{-2}	3000	0.0137	1.0793	203
50	10^{-2}	3000	0.0171	0.7698	781

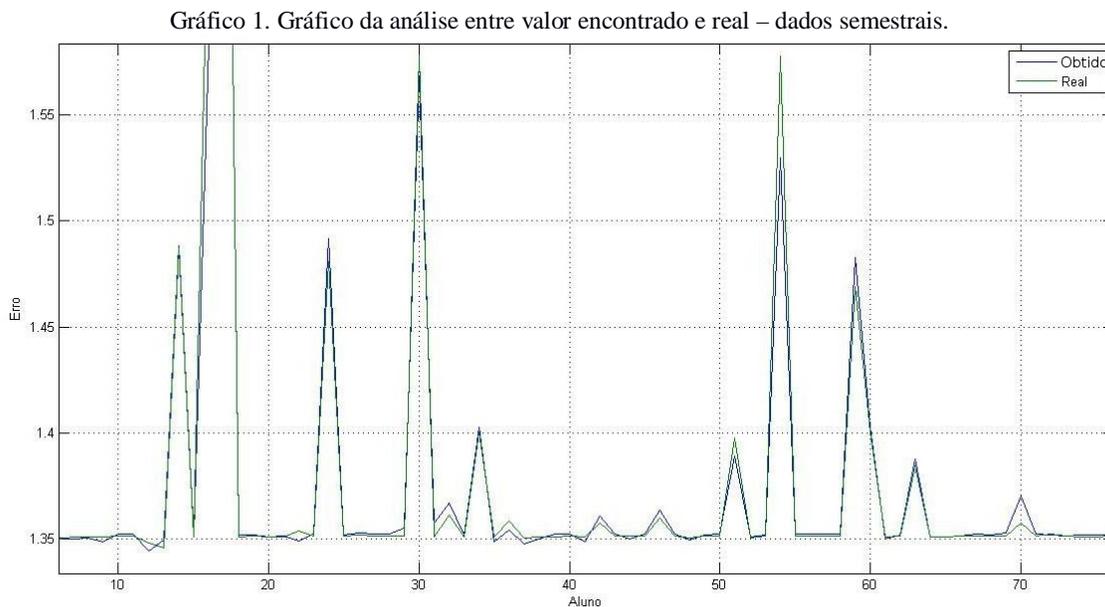
A combinação de parâmetros que apresentou o melhor resultado no erro médio foi: 50 unidades de neurônios, erro mínimo de 10^{-2} e 1000 épocas. Essa combinação encontrou o melhor erro médio (0.0030), porém apresentou um tempo de execução elevado (163 segundos), aproximadamente 6 vezes maior que o melhor tempo encontrado (27 segundos).

⁵ O treinamento de uma rede é executado ajustando ligeiramente os pesos depois de cada ciclo para reduzir o erro. Cada um desses ciclos é chamado de época. (RUSSELL; NORVIG, 2003).

A combinação de parâmetros que apresentou o melhor resultado no tempo de execução foi: 05 unidades de neurônios, erro mínimo de 10^{-2} e 1000 épocas. Essa combinação encontrou o melhor tempo de execução, porém apresentou um erro médio elevado em comparação ao melhor erro médio encontrado, aproximadamente 4,5 vezes maior.

O gráfico apresentado no Graf. 1 destaca uma comparação entre os dados reais (60 por cento do total) e os dados gerados pela rede (40 por cento do total). Podemos observar que na maior parte do gráfico as curvas estão sobrepostas, o que prova o bom resultado alcançado pela rede.

É possível concluir que a quantidade de neurônios utilizadas na rede tem grande influência sobre o erro médio obtido, pois o aumento desses neurônios apresentou extrema melhora dos resultados (para os dados semestrais).



Fonte: Elaborado pelos autores.

Foram realizados os experimentos para os dados anuais com os mesmos parâmetros utilizados com os dados semestrais, as mesmas funções de ativação e o mesmo algoritmo de treinamento. Os resultados são apresentados na Tab. 5.

Tabela 5. Resultados para os dados anuais na rede MLP.

Neurônios	Erro Mínimo	Épocas	Erro Médio	Erro Máximo	Tempo (segundos)
5	10^{-2}	1000	0.0249	0.7029	18
10	10^{-2}	1000	0.0364	0.7314	25
30	10^{-2}	465	0.0316	1.7269	35
50	10^{-1}	392	0.0340	1.8442	68
10	10^{-1}	1000	0.0106	0.8957	26
10	10^{-3}	1000	0.0547	0.9083	25
30	10^{-1}	896	0.0343	1.0841	68
8	10^{-1}	1000	0.0303	1.4399	22
10	10^{-1}	2000	0.0412	1.2905	51
10	10^{-2}	2000	0.0387	1.3091	49
5	10^{-1}	1000	0.0115	1.0945	19

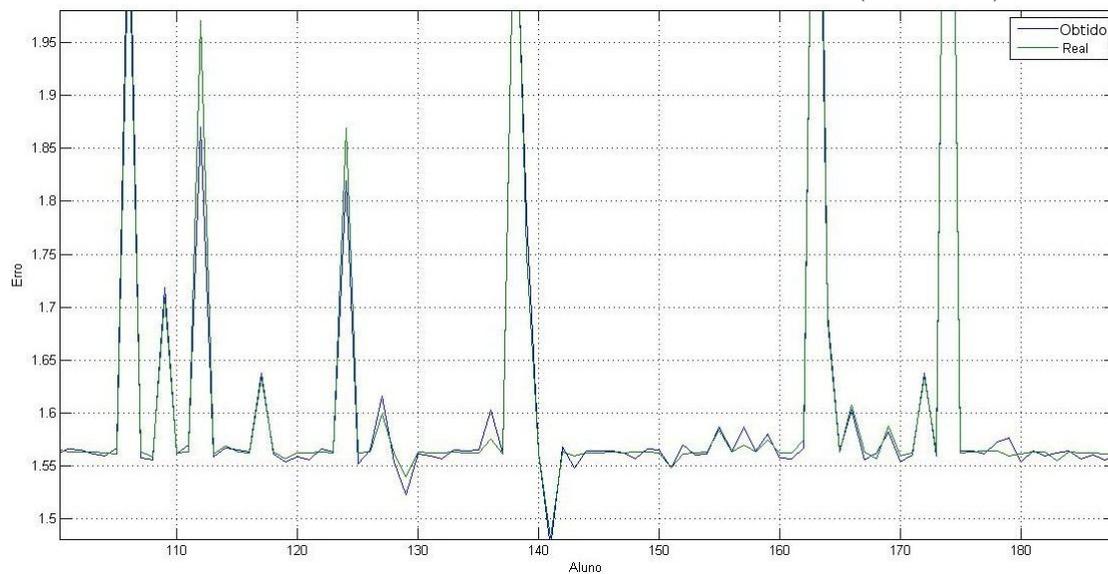
Fonte: Elaborada pelos autores.

A combinação de parâmetros que apresentou o melhor resultado no erro médio foi: 10 unidades de neurônios, erro mínimo de 10^{-1} e 1000 épocas. Essa combinação encontrou o melhor erro médio (0.0106).

A combinação de parâmetros que apresentou o melhor resultado no tempo de execução foi: 05 unidades de neurônios, erro mínimo de 10^{-2} e 1000 épocas. Essa combinação encontrou o melhor tempo de execução, porém apresentou um erro médio elevado em comparação ao melhor erro médio encontrado, aproximadamente 2.2 vezes maior.

O gráfico apresentado no Graf. 2 destaca uma comparação entre os dados reais e os dados gerados pela rede. É possível observar que na maior parte do gráfico as curvas estão sobrepostas, o que prova o bom resultado alcançado pela rede, entretanto cabe destacar que houve um aumento no erro médio dos dados anuais em comparação aos dados semestrais.

Gráfico 2. Gráfico da análise entre valor encontrado e real na rede MLP (dados anuais)



Fonte: Elaborado pelos autores.

4.2. Redes RBF

Os experimentos realizados com a rede RBF também foram executados para os dados semestrais e para os dados anuais da faculdade alvo do estudo.

Foram utilizadas algumas combinações de parâmetros e inicialmente variou-se a quantidade de *Spreads* (espelhamento), número máximo de neurônios e número de neurônios para adicionar entre os *displays* e notou-se que os resultados não sofriam alterações consideráveis, portanto fixou-se essas quantidades em 25. Sendo assim, alterou-se apenas o parâmetro de erro mínimo.

Para os dados semestrais os resultados alcançados são apresentados pela Tab. 6.

Tabela 6. Resultados para os dados semestrais na rede RBF

Erro Mínimo	Erro Médio	Erro Máximo	Tempo (segundos)
10^{-1}	0.0477	3.1689	1
10^{-2}	0.0374	3.1736	22
10^{-3}	0.0268	3.1959	118
10^{-4}	-	-	> 2000

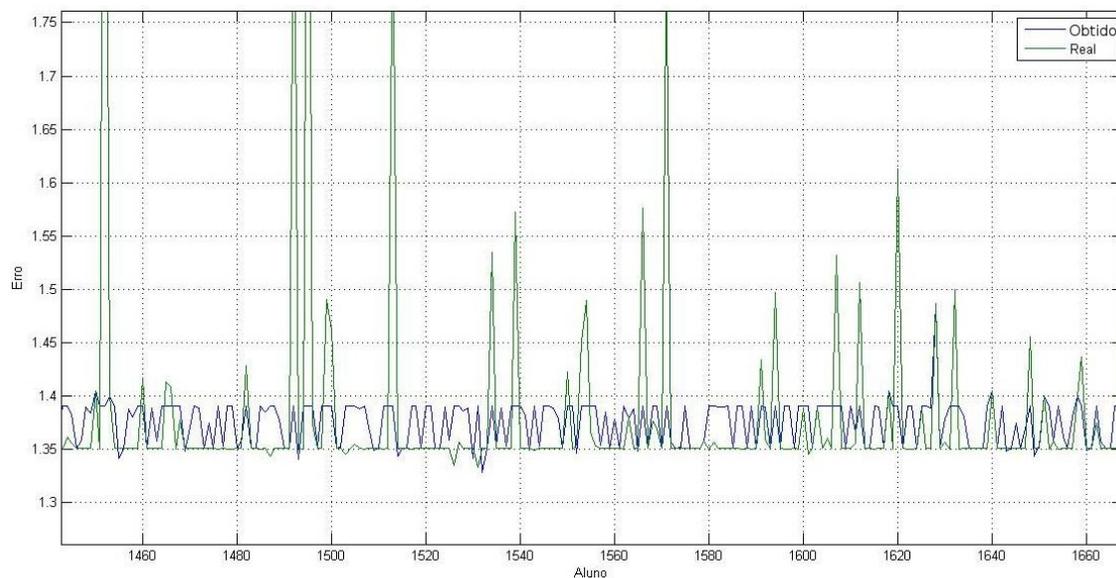
Fonte: Elaborada pelos autores.

É possível observar nos resultados apresentados pela Tab. 6 que o resultado foi melhorando consideravelmente ao alterar o parâmetro de erro mínimo, porém isso também acarretou aumentos consideráveis nos tempos de execução. Um exemplo claro desta afirmação pode ser observado quando aumentamos o erro mínimo de 10^{-2} para 10^{-3} . Ao realizar essa alteração obteve-se uma melhoria de aproximadamente 30 por cento no erro médio, porém um acréscimo de mais de 5 vezes no tempo de execução. Para o valor de erro mínimo de 10^{-4} o algoritmo demorou mais de 2000 segundos e optou-se por abandonar os experimentos nesse momento.

O gráfico apresentado no Graf. 3 destaca uma comparação entre os dados reais e os dados obtidos pela rede. Pode-se observar que na Rede RBF as curvas real e obtida não se sobrepõem em algumas vezes.

Para os dados anuais na rede RBF, utilizamos a mesma configuração de parâmetros dos dados semestrais e os resultados estão apresentados na Tab. 7.

Gráfico 3. Gráfico da análise entre valor encontrado e real na rede RBF (dados anuais).



Fonte: Elaborado pelos autores.

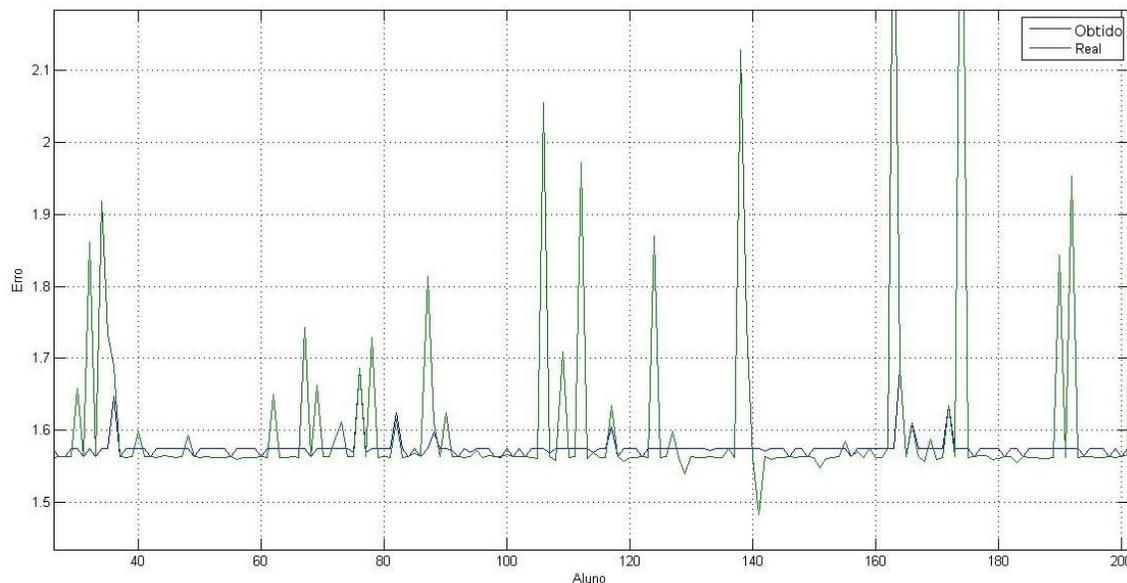
Tabela 7. Resultados para os dados semestrais na rede RBF

Erro Mínimo	Erro Médio	Erro Máximo	Tempo (segundos)
10^{-1}	0.0646	2.0825	1
10^{-2}	0.0573	2.0878	4
10^{-3}	0.0452	2.1130	17
10^{-4}	-	-	> 2000

Fonte: Elaborada pelos autores.

O gráfico apresentado no Graf. 4 destaca uma comparação entre os dados reais e os dados obtidos pela rede. Pode-se observar que na Rede RBF as curvas real e obtida não se sobrepõem na maioria das vezes.

Gráfico 4. Gráfico da análise entre valor encontrado e real na rede RBF – dados anuais



Fonte: Elaborada pelos autores

Pode-se observar que foram obtidas melhorias consideráveis no erro médio até chegar no valor de erro mínimo 10^{-4} , onde nesse ponto o tempo de execução tornou-se inviável, pois já havia ultrapassado os dois mil segundos e foi cancelado.

4.3. Redes Neuro-Fuzzy ANFIS

Todos os testes executados com as Redes Neuro-Fuzzy ANFIS não puderam ser completados devido as restrições de equipamentos. O computador sempre travou em todos os testes e não houve como observar nenhum resultado.

4.4. Considerações finais e trabalhos futuros

Não foram realizados mais experimentos variando ainda mais o erro mínimo e/ou as épocas, pois os resultados estavam piorando, o que pode ser devido ao viciamento da rede. Esse caso pode ser caracterizado como um *overfitting*, que acontece quando a rede memoriza os dados de treinamento ao invés de extrair os dados que permitirão a generalização.

Foi possível observar neste trabalho que a Rede MLP apresenta resultados de erro médio melhores que os da rede RBF para o tipo de problema utilizado e que o volume de dados (semestral x anual) tem influência destacável nos resultados obtidos, sendo esta a rede indicada para este tipo de trabalho. Além disso, alguns parâmetros têm grande influência sobre os resultados alcançados, principalmente o número de neurônios na rede MLP e o erro mínimo nos dois tipos de redes.

Como trabalhos futuros sugere-se realizar os experimentos em equipamentos com maior capacidade computacional, pois foi possível perceber que a limitação de recursos computacionais afetaram os experimentos negativamente. Com um recurso melhor será possível, no futuro, variar ainda mais os parâmetros e, com isso, obter resultados mais conclusivos e definitivos, além de poder realizar experimentos em outros tipos de redes.

5. CONCLUSÃO

Este trabalho contribuiu com apresentação de uma proposta de treinamento de uma rede neural que gera uma solução computacionalmente inteligente para o problema da previsão de inadimplência de alunos do ensino superior de instituições particulares. Por meio de dados reais de alunos de uma instituição de ensino superior foi possível construir 3 tipos de redes neurais e avaliar 2 delas completamente, sabendo que os testes em uma dessas redes foi inviável devido a limitação do equipamento.

Uma dessas redes, a MLP, destacou-se ao apresentar um resultado mais satisfatório em comparação a outra rede, a RBF, e foi possível concluir ainda que alguns parâmetros dessas redes,

tais como o número de neurônios, a quantidade de épocas e o erro mínimo, têm grande influência nos resultados e seus valores devem ser cuidadosamente atribuídos para se obter resultados satisfatórios no treinamento e teste da rede neural.

Como o resultado obtido apresentado pela rede MLP ficou bastante próximo do real utilizando os mesmos dados de entrada, é possível concluir que este método de previsão é satisfatório e passível de ser utilizado pra prever o pagamento de mensalidades pelos alunos.

REFERÊNCIAS

ABRAHAM, A. **Neuro fuzzy systems**: State-of-the-art modeling techniques. In: AND ARTIFICIAL INTELLIGENCE, SPRINGER-VERLAG GERMANY, JOSE MIRA AND ALBERTO PRIETO. EDS, p. 269–276, Springer Verlag, 2001.

BRAGA, A. D. P.; CARVALHO, A. P. D. L. F.; LUDERMIR, T. **Redes neurais artificiais**: teoria e aplicações. 2.ed. LTC, 2011.

BRAGA, A. Paduá. **Redes neurais artificiais**: teoria e aplicações. LTC, 2000.

CHIAVENATO, Idalberto. **Introdução à Teoria Geral da Administração**. 8. ed. São Paulo: Campus, 2011.

HAYKIN, S. **Redes neurais**: princípios e praticá. Bookman, 2001.

HERLING, L.; MORITZ, G. A inadimplência nas instituições de ensino superior: um estudo de caso na instituição xzx. **Revista Gestão Universitária na América Latina - GUAL**, v. 6, n. 2), p. 126–142, 2013.

INEP. **Inep**: censo da educação superior. 2013.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. 2015.

JANG, J. S. R. Anfis: Adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 23, p. 665–685, 1993.

MALVINO, A. Paul. **Microcomputadores e Microprocessadores**. São Paulo: McGraw-Hill, 1985.

MENDEL, J. M.; MCLAREN, R. W. **A prelude to neural networks**: chapter Reinforcement-learning Control and Pattern Recognition Systems. Prentice Hall Press, Upper Saddle River, NJ, USA, 1994. p. 287-318.

REZENDE, S. **Sistemas inteligentes**: fundamentos e aplicações. Manole, 2003.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 2.ed. Pearson Education, 2003.

SANCHES, A.; ZENI, A. **Concessão de crédito em uma instituição de ensino baseada em redes neurais artificiais**. In: SEGET 2013 - SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA, v. 23, p. 15–25, 2013.

SILVA, I. da; SPATTI, D.; FLAUZINO, R. **REDES NEURAIS ARTIFICIAIS PARA ENGENHARIA E CIENCIAS APLICADAS: CURSO PRATICO**. ARTLIBER, 2010.

USBERTI, F. L. **Simanfis**: Simplificação da arquitetura neuro-fuzzy anfis. In: XXXIX SBPO - PESQUISA OPERACIONAL E O DESENVOLVIMENTO SUSTENTÁVEL, v. 4, p. 25–35, 2007.