

## REDE NEURAL ARTIFICIAL: IDENTIFICAÇÃO DE ACADÊMICOS EM CURSO DE LICENCIATURA EM MATEMÁTICA COM POSSIBILIDADE DE DESISTÊNCIA

*ARTIFICIAL NEURAL NETWORK: IDENTIFICATION OF ACADEMIC SCHOOLS WITH MATHEMATICS*

Alyne de Castro Santana Rocha<sup>1</sup>

Ana Maria Negreiros Magalhães Neta<sup>1</sup>

Leonardo Pires de Sá<sup>1</sup>

Walber Rodrigues de Assis<sup>1</sup>

Guilherme Feitoza de Sousa Lima<sup>2</sup>

Francisco Alves dos Santos.<sup>3</sup>

**RESUMO:** Este trabalho desenvolveu-se no âmbito do Instituto Federal de Educação, Ciência e Tecnologia do Piauí – IFPI, *Campus* São Raimundo Nonato, cujo objetivo principal foi avaliar a capacidade de uma rede neural artificial Perceptron Multicamadas em identificar acadêmicos de Licenciatura em Matemática com possibilidade de evadir-se do curso. A metodologia empregada dividiu-se em 03 etapas: A primeira etapa, foi destinada a um levantamento junto ao controle acadêmico do Campus; na etapa seguinte, realizou-se uma pesquisa com acadêmicos de Licenciatura em Matemática; a terceira etapa, examinou-se a eficiência da rede neural artificial, através do software Weka, para prever evasões de acadêmicos. Os resultados obtidos decorrem da utilização de tecnologias da informação, no qual, deduziu-se ser viável utilizar uma rede neural artificial para prever desistências de acadêmicos de um curso de Licenciatura em matemática.

**Palavras-chave:** Desistências. Licenciatura. Matemática. Rede Neural Artificial.

**ABSTRACT:** This work was developed in the framework of the Federal Institute of Education, Science and Technology of Piauí - IFPI, São Raimundo Nonato Campus, whose main objective was to evaluate the ability of a Multilayer Perceptron artificial neural network to identify undergraduate mathematics students with the possibility to drop out the course. The methodology employed was divided into three stages: The first stage was destined to a survey along the academic control of the campus; In the next stage, we performed a study with undergraduate students in Mathematics; In the third stage, we examined the efficiency of the artificial neural network, through the Weka software, to predict academic dropouts. The results arising from the use of information technologies, which inferred that it is feasible to use an artificial neural network to predict dropouts of academics from a Mathematics Degree course.

**Keywords:** Dropouts. Graduation. Mathematics. Artificial neural network.

<sup>1</sup> Acadêmicos de Licenciatura em Matemática pelo Instituto Federal do Piauí – IFPI, *Campus* São Raimundo Nonato;

<sup>2</sup> Bacharel em Sistemas de Informação pela Universidade Federal do Piauí, *Campus* Picos, e Técnico em desenvolvimento de software do Instituto Federal do Piauí – IFPI, *Campus* São Raimundo Nonato;

<sup>3</sup> Professor de matemática do Instituto Federal do Piauí – IFPI, *Campus* São Raimundo Nonato.

## INTRODUÇÃO

A evasão nos cursos de Licenciatura é fenômeno recorrente, visto que em média apenas 30% dos ingressantes concluem a graduação (Gatti 2011, p.105 Apud Bittar). quando analisado um caso particular do curso de Licenciatura em Matemática ofertado pelo IFPI, *Campus* São Raimundo Nonato desde 2011, a questão é igualmente delicada, no qual, segundo dados do controle acadêmico do *Campus*, dos 120 acadêmicos matriculados nos três primeiros anos de curso, apenas 24 concluíram, o que equivale a 20% do total de ingressantes. Ainda vale ressaltar que dos 24 dos formados, 08 acabaram precisaram repetir alguma disciplina.

Nestas circunstâncias, surge a necessidade de identificar com antecedência os acadêmicos, que por algum motivo, possa haver fatores que interfira em sua aprendizagem, resultando em reprovações e decorrente disso, leve-os a evadir-se do curso. Com isso, buscamos examinar variáveis dos atuais acadêmicos do curso de Licenciatura em Matemática, e com auxílio de ferramentas de tecnologia da informação que permitisse identificar através dessas variáveis, o potencial de um acadêmico, para a desistência.

Assim estabelecemos como objetivo principal avaliar a capacidade de uma rede neural artificial Perceptron Multicamadas em identificar acadêmicos de Licenciatura em Matemática com possibilidade de evadir-se do curso. Como objetivos específicos: Coletar dados referentes à rotina dos acadêmicos de Licenciatura em Matemática; medir a eficiência da rede neural artificial por meio do softwera Weka; examinar, se com as informações obtidas, um programa pode ser utilizado por instituições de ensino superior para identificar um acadêmico com potencial de desistência

## APORTE TEÓRICO

### Dificuldades em Matemática

São comuns os casos de discentes com dificuldades quando o assunto é o ensino-aprendizado de conteúdos matemáticos. Tal fato, acarreta inúmeros casos de insucesso quando existe a necessidade desses conhecimentos, e isso acaba se arrastam naturalmente ao longa da vida acadêmica. A respeito disso, VITTI (1999 p.19) nos diz:

O fracasso do ensino de matemática e as dificuldades que os alunos apresentam em relação a essa disciplina não é um fato novo, pois vários educadores já elencaram elementos que contribuem para que o ensino da matemática seja assinalado mais por fracassos do que por sucessos. (Apud Santos 2007 p.27)

Ao olharmos para um curso de licenciatura em matemática, o cenário não é diferente, no qual, é corriqueiro encontrar acadêmicos com grande dificuldade nas disciplinas específicas. Esses obstáculos, resultantes, em alguns casos, de uma educação básica frágil que não fornece, em sua maioria, o aporte de conhecimentos matemáticos discutidos de modo a suprir os discentes, com um entendimento das generalizações e as situações de aplicabilidade e sobretudo, compreender os meios de resolver cada atividade proposta. Sobre isso, Cury (2007. Apud Pereira p.3) relata que:

A formação de professores de Matemática tem mostrado que muitos acadêmicos, ao iniciar um Curso de Licenciatura em Matemática, enfrentam dificuldades ligadas ao conteúdo específico da disciplina, trazidas da educação básica, o que muitas vezes se arrasta por toda a graduação inclusive gerando dificuldades na aprendizagem dos conteúdos matemáticos ditos da formação inicial.

Esses fatos ajudam a explicar o pequeno número de formados por um curso licenciatura em matemática. Entretanto, não é aceitável que haja tantos fracassos relacionados ao ensino-aprendizado dessa disciplina, visto a importância do conhecimento de seus temas de estudo.

### Rede Neural Artificial

As redes neurais artificiais (RNAs) são intuitivamente definidas por Goldschmidt (2010), como modelos matemáticos que aplicam técnicas computacionais inspiradas no funcionamento do cérebro. Esses modelos, por meio do reconhecimento de padrões, podem adquirir competências, como por exemplo, a capacidade de aprendizado de máquinas.

Em termos intuitivos, redes neurais artificiais (RNAs) são modelos matemáticos inspirados nos princípios de funcionamento dos neurônios biológicos e na estrutura do cérebro. Estes modelos têm capacidade de adquirir, armazenar e utilizar conhecimento experimental e buscam simular computacionalmente habilidades humanas tais como aprendizado, generalização, associação e abstração. (Goldschmidt 2010, p.72)

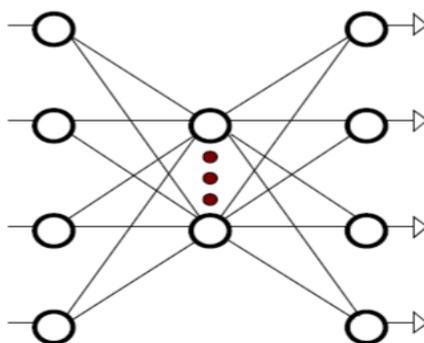
Segundo Ferneda (2006), uma rede neural possui como unidades fundamentais de processamento de informação os neurônios, interligados através de conexões sinápticas. O autor destaca que “as redes neurais artificiais se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado” (p.26).

A perceptron multicamadas, por exemplo, apresentam unidades intermediárias, isto é, os neurônios são organizados em duas ou mais camadas de processamento.

No modelo dos perceptrons multi-camadas, entre uma camada e outra, existe uma matriz de pesos. A regra de propagação é a combinação entre as saídas de cada unidade e a

matriz de pesos. Ela é realizada através da soma ponderada de cada sinal que chega, via conexões, pelo respectivo peso. O estado de ativação assume valores contínuos e devido a isto a regra de ativação das unidades utiliza como função de ativação uma função do tipo sigmóide. (Portugal e Fernandes, 1996, p.13)

**Figura 01:** Topologia genérica do perceptron multi-camadas.



Fonte: Portugal e Fernandes.

A imagem 02 evidencia as conexões que fazem a “comunicação” entre as camadas, no qual, as camadas intermediárias encontram-se situadas da esquerda para direita entre a camada de entrada e a camada neural de saída.

## MATERIAIS E MÉTODOS

Os métodos aplicados, conforme classificação FONSECA (2002), foram de cunho quantitativo, dividindo-se em 03 etapas. Inicialmente, verificou-se através de um levantamento junto ao Controle Acadêmico do *Campus*, informações acerca dos acadêmicos egressos do curso, bem como, dados sobre os ingressantes de cada ano letivo.

Em seguida, realizou-se uma pesquisa com 61 dos atuais acadêmicos do curso de Licenciatura em Matemática. Isso deu-se mediante preenchimento de um questionário objetivo que continha 07 perguntas, no qual, abordou-se questões referente à suas respectivas rotinas.

A última etapa, destinou-se para organização dos dados e procurou-se também, verificar a possibilidade de utilizar posteriormente essa técnica em softwares. Para isso, utilizou-se as informações coletadas através da pesquisa realizada na segunda etapa do trabalho, juntamente com algoritmos para treinamento de redes neurais artificiais fornecidos pelo software Weka.

Sobre o Software Weka

Conforme o site Weka, o mesmo trata-se de uma ferramenta desenvolvida pela Universidade de Waikato, Nova Zelândia. Trata-se de um software livre com código aberto emitido

sob a GNU General Public License, no qual, disponibiliza uma coleção de algoritmos para serem utilizados em estudos de aprendizagem de máquina para tarefas de mineração de dados.

## RESULTADOS E DISCURSÃO

Apresentaremos nesta seção, os processos de experimentação utilizado para atingir o objetivo desse trabalho. O experimento iniciou-se no início de 2018 com a coleta de dados referente a rotina dos acadêmicos através de um formulário contendo sete questões, como segue:

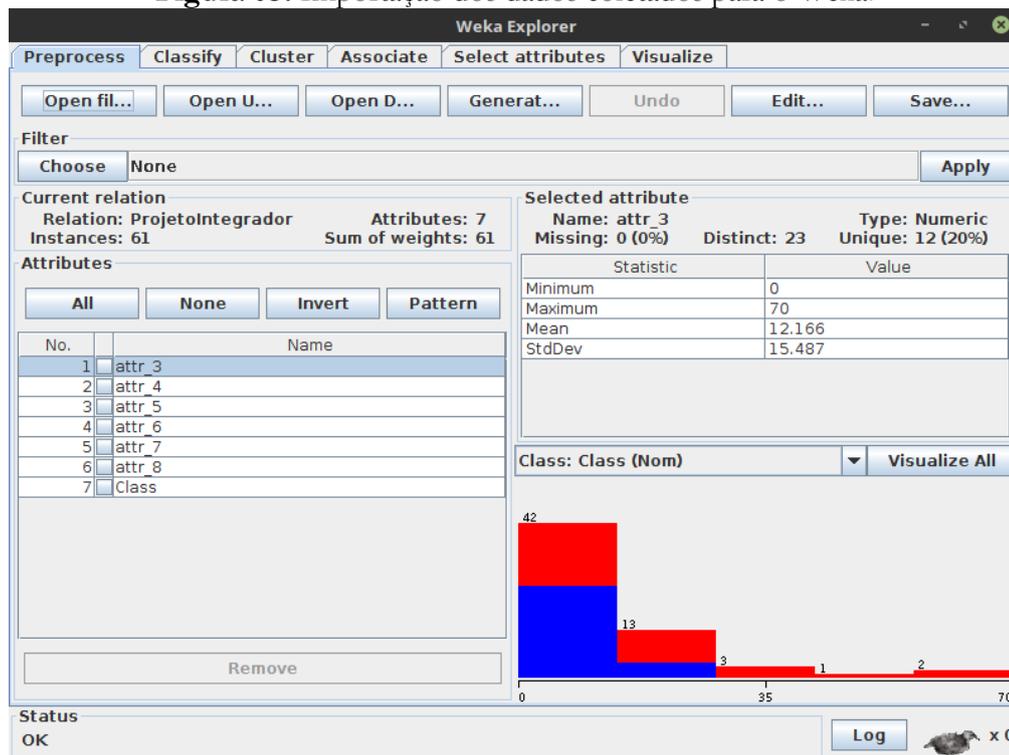
### Figura 02: Questionário.

- 1° - Quantas horas semanais dedica para estudar?
- 2° - Costuma realizar leituras em artigos científicos, revistas, livros, etc.?  
 Sim       Não
- 3° - Quanto tempo reserva para descansar (dormir)?
- 4° - Reprovou em alguma disciplina?  
 Sim. Quantas? \_\_\_\_\_       Não
- 5° - Com que frequência falta as aulas?  
 Sempre     Quase sempre     As vezes  
 Raramente     Nunca
- 6° - Durante a graduação, esteve (ou está) envolvido (a) em outras atividades acadêmicas?  
 Sim       Não
- 7° - Trabalha?  
 Sim       Não

Fonte: dados da pesquisa.

Esses dados coletados passaram por um processo de organização, em que, alguns campos do questionário foram representados numericamente e outros de forma booleana. A partir disto, os dados foram dispostos em uma tabela, no qual, foi criado duas colunas com as seguintes classificações para os acadêmicos: *potencial desistente*, para acadêmicos com características não exemplares, como por exemplo, não dedicar-se aos estudos, possuir alguma reprovação no curso, etc. e como *aluno regular* para os demais.

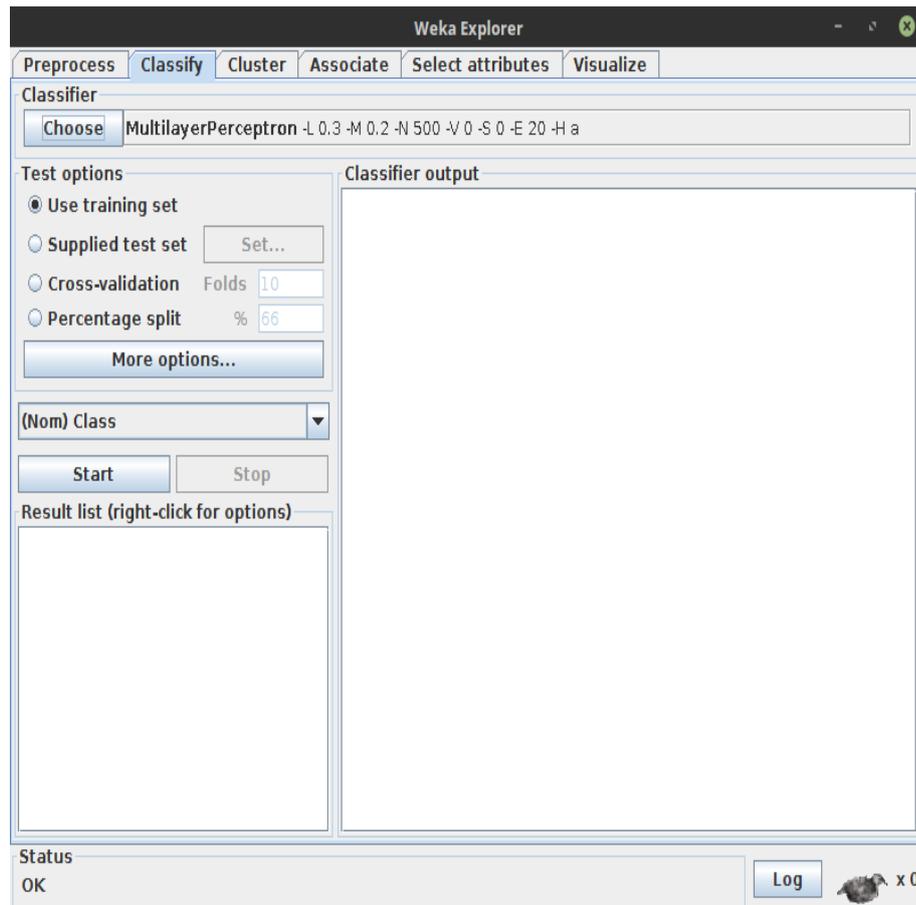
Posteriormente os dados levantados foram computados em um arquivo, para serem utilizados no software Weka. A figura 03, apresenta a importação do arquivo para o aplicativo.

**Figura 03:** Importação dos dados coletados para o Weka.

Fonte: dados da pesquisa.

Após a importação dos dados, foi selecionado o algoritmo de Rede Neural Artificial Perceptron Multicamada para aprender a identificar alunos com potencial de abandonar o curso. A figura 04 apresenta o algoritmo selecionado no programa.

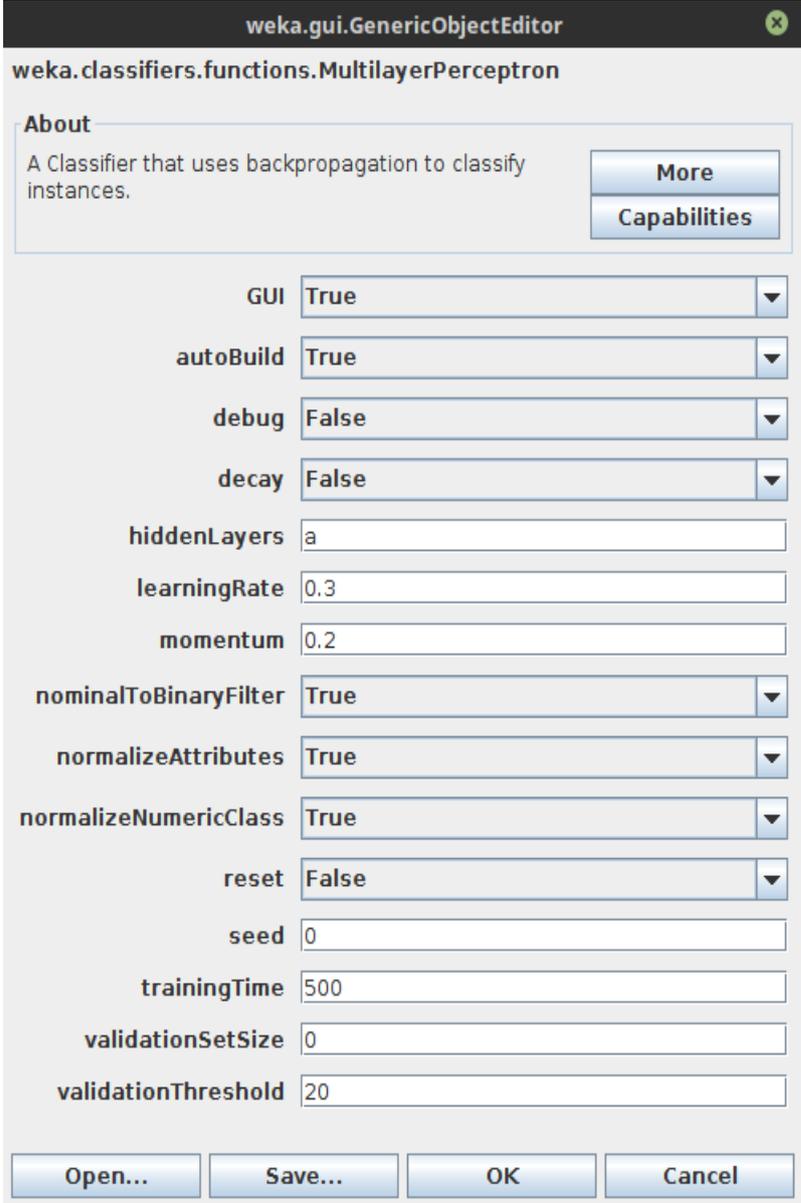
**Figura 04:** Seleção do algoritmo de rede neural.



Fonte: dados da pesquisa.

Após a seleção do algoritmo, seguiu-se para configurar os parâmetros da rede neural. Os parâmetros utilizados foram os padrões definidos pela ferramenta: taxa de aprendizado de 0.3, tempo de treinamento igual a 500, número de neurônios padrão do weka calculado pela equação:  $n_1 = n + nc/2$ , no qual,  $n$  representa o número de neurônios,  $nc$  o número de classes, os demais parâmetros são apresentados na figura 05.

Figura 05: Parâmetros de configuração da rede neural.



The image shows a screenshot of the Weka GUI for the MultilayerPerceptron classifier. The window title is "weka.gui.GenericObjectEditor". The main title is "weka.classifiers.functions.MultilayerPerceptron". There is an "About" section with the text "A Classifier that uses backpropagation to classify instances." and two buttons: "More" and "Capabilities". Below this are various settings:

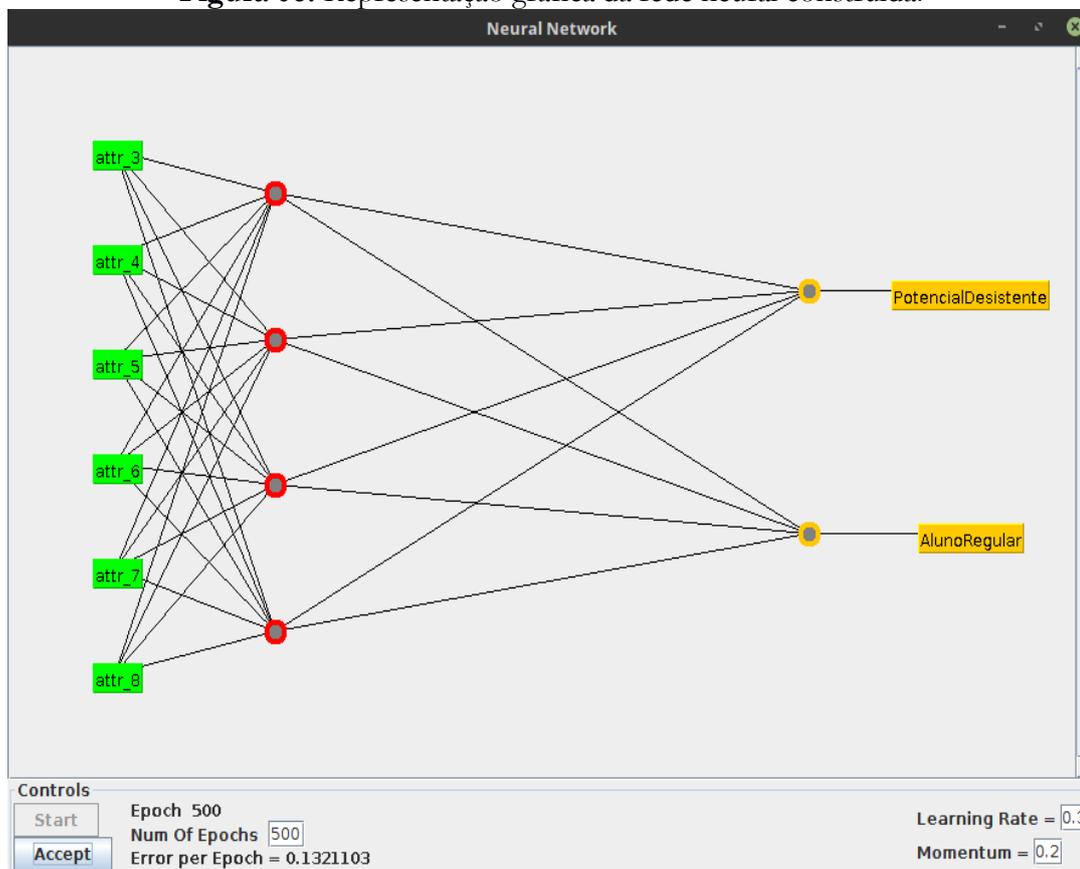
Property	Value
GUI	True
autoBuild	True
debug	False
decay	False
hiddenLayers	a
learningRate	0.3
momentum	0.2
nominalToBinaryFilter	True
normalizeAttributes	True
normalizeNumericClass	True
reset	False
seed	0
trainingTime	500
validationSetSize	0
validationThreshold	20

At the bottom, there are four buttons: "Open...", "Save...", "OK", and "Cancel".

Fonte: dados da pesquisa.

A figura 06 apresenta a estrutura da rede neural utilizada no experimento.

**Figura 06:** Representação gráfica da rede neural construída.

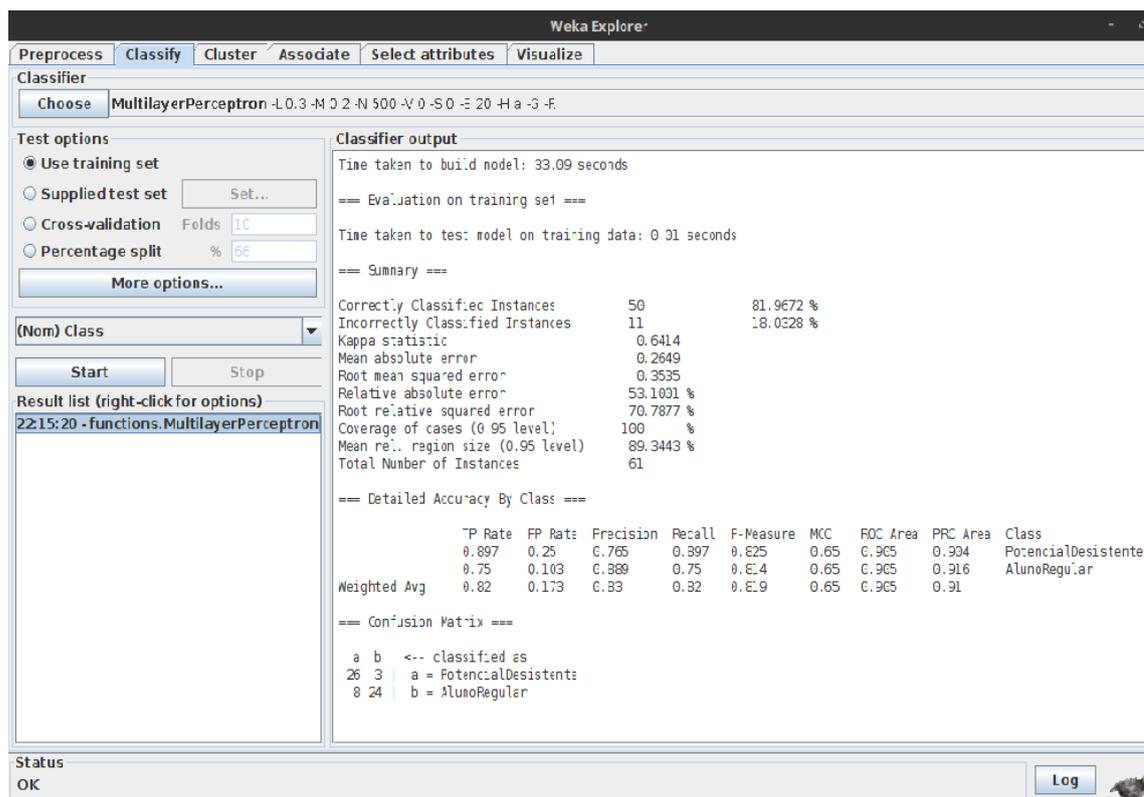


Fonte: dados da pesquisa.

Após a execução do treinamento, etapa em que, a rede neural realizou ajustes para construir um modelo do que é compreendido por ela como um aluno “Potencial desistente” ou “Aluno regular” a partir dos dados de entrada, no qual, que para esta rede neural são: horas dedicadas a estudo semanalmente, tempo dedicado a leitura, hora de sono, hora dedicada a atividade profissional, frequência com que assiste as aulas e participação em atividades extracurriculares. Após esse aprendizado a rede foi utilizada para classificar todos os alunos a partir dos dados citados acima.

Foi obtido uma taxa de acerto de 81.9672% na identificação de alunos com potencial de abandonar o curso e uma taxa de erro de 18.0328 %, em que, 50 instâncias foram classificadas corretamente e 11 classificadas de forma errada. Existe a possibilidade de aumento da acurácia da rede com a utilização de mais dados para treinar, pois nesse experimento foram utilizadas informações de apenas 61 alunos. A figura 07 apresenta os resultados obtidos pela ferramenta weka.

**Figura 07:** Resultado obtido no experimento.



**Weka Explorer**

Preprocess | **Classify** | Cluster | Associate | Select attributes | Visualize

Classifier: Choose MultilayerPerceptron -L0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H a -G -F

Test options:  
 Use training set  
 Supplied test set (Set...)  
 Cross-validation (Folds: 10)  
 Percentage split (%: 66)  
 More options...

Classifier output:  
 Time taken to build model: 33.09 seconds  
 == Evaluation on training set ==  
 Time taken to test: model on training data: 0.01 seconds  
 == Summary ==  
 Correctly Classified Instances: 50 (81.9672 %)  
 Incorrectly Classified Instances: 11 (18.0328 %)  
 Kappa statistic: 0.6414  
 Mean absolute error: 0.2649  
 Root mean squared error: 0.3535  
 Relative absolute error: 53.1031 %  
 Root relative squared error: 70.7877 %  
 Coverage of cases (0.95 level): 100 %  
 Mean rel. region size (0.95 level): 89.3443 %  
 Total Number of Instances: 61  
 == Detailed Accuracy By Class ==

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
Weighted Avg	0.897	0.25	0.765	0.897	0.825	0.65	0.905	0.304	PotencialDesistente
	0.75	0.103	0.889	0.75	0.814	0.65	0.905	0.316	AlunoRegular

== Confusion Matrix ==

```

a b <-- classified as
26 3 | a = PotencialDesistente
8 24 | b = AlunoRegular

```

Status: OK

Fonte: dados da pesquisa.

## CONSIDERAÇÕES FINAIS

Através da pesquisa, foi possível colher informações para a simulação através do Weka, de tal modo que oportunizou identificar características dos acadêmicos que possuem alguma reprovação. Além disso, permitiu corroborar que muitos discentes evadem-se culminando no baixo número de acadêmicos que concluem o curso.

Quanto a experiência com o Weka, visto que, a avaliação da utilização da técnica de aprendizado de máquina redes neurais artificiais perceptron multicamadas apresentou resultados satisfatório, no que se refere ao processo de classificação dos acadêmicos do curso de licenciatura em matemática, torna-se viável utilizá-la para prever possíveis desistências. No qual, ficara a cargo de trabalhos futuros, o desenvolvimento de software que empregue os resultados aqui obtidos.

Desse modo, o software a ser desenvolvido servirá de auxílio na identificação de acadêmicos com carências, uma vez que será possível diagnosticar, por exemplo, um acadêmico ingressante, como potencial desistente, mediante algumas perguntas simples sobre sua rotina semanal. Fato que permitirá aos profissionais de ensino das instituições de curso superior, intervirem com intuito de minimizar evasões de acadêmicos.

## REFERÊNCIAS BIBLIOGRÁFICAS

BITTAR, Marilena, et.al. (2012). **A evasão em um curso de matemática em 30 anos.**

Disponível em: <<https://periodicos.ufpe.br/revistas/emteia/article/view/2168>>. Acesso em: 28 de fev. de 2018.

FERNANDES, Luiz Gustavo L. e PORTUGAL Marcelo S (1996). **Redes Neurais Artificiais e Previsão de Séries Econômicas: Uma Introdução.** Disponível em:

<[http://www8.ufrgs.br/ppge/pcientifica/1995\\_01.pdf](http://www8.ufrgs.br/ppge/pcientifica/1995_01.pdf)>. Acesso em: 28 de fev. de 2018.

FERNEDA, Edberto (2006). **Redes neurais e sua aplicação em sistemas de recuperação de informação.** Disponível em: <<http://www.scielo.br/pdf/%0D/ci/v35n1/v35n1a03.pdf>>.

Acesso em: 28 de fev. de 2018.

FONSECA, J. J. S. Metodologia da pesquisa científica. 2002.

GOLDSCHMIDT, Ronaldo Ribeiro (2010). **Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações.** Disponível em:

<<http://www.boente.eti.br/boente2012/fuzzy/ebook/ebook-fuzzy-goldschmidt.pdf>> Acesso em: 28 de fev. de 2018.

PEREIRA, Larissa Ranyelly Branquinho et.al. (2016). **Dificuldades enfrentadas pelos futuros professores no curso de licenciatura integrada em matemática e física na UFOPA.**

Disponível em: <[http://www.sbem.com.br/enem2016/anais/pdf/4809\\_3526\\_ID.pdf](http://www.sbem.com.br/enem2016/anais/pdf/4809_3526_ID.pdf)> Acesso em: 28 de fev. de 2018.

SANTOS, Josiel Almeida, et.al (2007). **Dificuldades na Aprendizagem de Matemática.**

Disponível em:

<[http://www.educadores.diaadia.pr.gov.br/arquivos/File/2010/artigos\\_teses/MATEMATICA/Monografia\\_Santos.pdf](http://www.educadores.diaadia.pr.gov.br/arquivos/File/2010/artigos_teses/MATEMATICA/Monografia_Santos.pdf)>. Acesso em: 28 de fev. de 2018.

WEKA, The University of Waikato. Disponível em:

<<https://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em 28 de fev. de 2018.