

UM SISTEMA INTELIGENTE USANDO REDES NEURAIAS ARTMAP-FUZZY PARA PREDIÇÃO DO GRUPO DE RISCO DE EVASÃO DISCENTE EM CURSOS SUPERIORES PRESENCIAIS

VALQUÍRIA R. DE C. MARTINHO¹, CLODOALDO NUNES², CARLOS R. MINUSSI³.

1. Departamento de Eletro-Eletrônica, Instituto Federal de Mato Grosso - IFMT - Campus Cuiabá
Rua Zulmira Canavarros, 93 - Centro - Cuiabá / MT, Brasil - CEP: 78005-200
2. Departamento de Informática, Instituto Federal de Mato Grosso - IFMT - Campus Cuiabá
Rua Zulmira Canavarros, 93 - Centro - Cuiabá / MT, Brasil - CEP: 78005-200
3. Laboratório de Sistemas Inteligentes, Faculdade de Engenharia Elétrica de Ilha Solteira - UNESP
Av. Prof. José Carlos Rossi, 1370 - Ilha Solteira / SP, Brasil - CEP: 13385-000
vrubeiro@terra.com.br, cncefet@gmail.com, minuissi@dee.feis.unesp.br

Abstract— School dropout permeates the various levels and teaching modalities and has generated social, economic, political, academic and financial damage to all involved in the educational process. Data about school dropout in higher education courses show the worrying state of fatigue and weakness of Brazilian higher education. Therefore, it is fundamental to develop efficient methods for prediction, assessment and monitoring of the students at risk of dropping out, making the planning and adoption of proactive actions possible to minimize the situation. In this context, this work aims to present the potentialities of an intelligent system developed for the prediction of the group of students at risk of dropping out in higher education classroom courses. The system was developed using a Fuzzy-ARTMAP Neural Network, one of the artificial intelligence techniques, which makes the continued learning of the system possible. It was implemented in the technology courses of the Federal Institute of Mato Grosso, based on the academic and socioeconomic records of the students. The results, showing a success rate of the dropout group around 95% and overall accuracy over 76%, highlights the reliability and accuracy of the system. Furthermore, it is noteworthy that the strength and boldness of this research lies in the possibility of identifying early the eminent school dropout using only the enrollment data.

Keywords— Dropout prediction, Intelligent System, Fuzzy-ARTMAP Neural Network, Proactivity.

Resumo— A evasão escolar permeia os vários níveis e modalidades de ensino e tem gerado prejuízos sociais, econômicos, políticos, acadêmicos e financeiros a todos os envolvidos no processo educacional. Os dados sobre evasão nos cursos superiores demonstram o preocupante estado de fadiga e fragilidade que se encontra a educação superior brasileira. Portanto, torna-se imprescindível o desenvolvimento de métodos eficientes para predição, avaliação e acompanhamento de estudantes em risco de evasão, possibilitando o planejamento e adoção de medidas proativas para minimizar a situação. Nesse contexto, este trabalho objetiva apresentar as potencialidades de um sistema inteligente desenvolvido para predizer o grupo de estudantes em risco de evasão, em cursos superiores presenciais. O sistema foi desenvolvido utilizando uma Rede Neural ARTMAP-Fuzzy, uma das técnicas da inteligência artificial, com possibilidade de aprendizado continuado. Implementou-se este sistema nos cursos superiores de tecnologia do Instituto Federal de Mato Grosso, baseado nos registros acadêmicos e socioeconômicos dos estudantes. Diante dos resultados, acerto do grupo evasivo em torno de 95% e acerto global superior a 76%, evidencia-se a fidedignidade e acurácia do sistema. Ressalta-se, ainda, que a pujança e a audácia desta pesquisa encontra-se na possibilidade identificar precocemente a iminente evasão usando somente os dados da inscrição.

Palavras-chave— Predição da Evasão Escolar, Sistema Inteligente, Rede Neural ARTMAP-Fuzzy, Proatividade.

1 Introdução

Ao longo da história da Educação, o fenômeno da evasão escolar permeia os vários níveis e modalidades de ensino e tem gerado prejuízos sociais, econômicos, políticos, acadêmicos e financeiros a todos os envolvidos no processo educacional. É um problema complexo e crucial (Martinho, 2012), advindo da superposição de fatores endógenos e exógenos da instituição de ensino, além de variáveis demográficas e atributos individuais que influenciam na decisão do estudante universitário de permanecer ou abandonar o curso.

O preocupante estado de fadiga e fragilidade que se encontra a educação superior brasileira é ratificado pelos índices da evasão no ensino superior, em torno de 20,5% entre as instituições de ensino superior públicas e privadas, de acordo com o relatório do Censo da Educação Superior 2011.

Não obstante, por meio de um estudo estatístico no Curso Superior de Tecnologia (CST) em Automação Industrial, do Instituto Federal de Mato Grosso (IFMT), *locus* de desenvolvimento desta pesquisa, no período de 2004-2010, constatou-se que dos 389 estudantes matriculados no curso, 233 estão evadidos, representando um índice de 62,46% de evasão (Barbosa, 2010). O IFMT assumiu uma meta desafiadora de reduzir para 10% o índice de evasão na instituição até 2016.

Nesse contexto, diante da complexidade do fenômeno e a necessidade de encontrar soluções, é imprescindível realizar estudos sistemáticos, observar os sinais de evasão iminente, desenvolver estratégias para identificar previamente os estudantes propensos à evasão. Isso, com o intuito de possibilitar a articulação de um conjunto de medidas e ações proativas destinadas a manter o estudante na instituição. Os métodos preditores da evasão são factíveis de serem empregados de maneira coletiva. Porém, a

ação em prol da permanência do estudante deve ser individualizada, atendendo suas necessidades específicas. Esta convicção vai ao encontro do que enfatiza a UNESCO, de que a evasão pode constituir-se em fenômeno coletivo, mas é sempre num processo individual.

As variáveis envolvidas no processo da evasão guardam em si uma gama de especificidades inerentes aos diferentes níveis de ensino, cursos e instituições que se possa analisar, são complexas, subjetivas, não-lineares e inter-relacionadas. Uma possibilidade factível para representar situações de complexidade, não-linearidade e subjetividade, como o caso da evasão escolar, é a utilização de Redes Neurais Artificiais (RNAs) (Haykin, 2009), um dos paradigmas da Inteligência Artificial (IA) (Nilsson, 1998).

As Redes Neurais são sistemas computacionais que emulam o cérebro humano na interpretação e processamento das informações e, também, “aprendem” através de experiências, tornando-as capazes de fazer generalizações mais confiáveis. Essa capacidade permite o desenvolvimento de sistemas com habilidade para processar problemas intratáveis, lidar com variáveis não-lineares, imperfeitas e faltantes, interagir com dados ruidosos e, mesmo assim, apresentar rapidez e precisão nos resultados.

Na literatura, foram encontradas poucas referências pertinentes a análise e predição da evasão escolar discente, em cursos presenciais do ensino superior, utilizando redes neurais artificiais. Os trabalhos mais próximos foram o de Lykourantzou *et al.* (2009) que investiga o grupo de risco de estudantes com propensão à evasão em cursos e-learning. Utiliza-se a combinação de três técnicas de aprendizagem de máquina, entre elas a rede neural ARTMAP-Fuzzy e, o de Mustafa (2012) que utiliza árvore de regressão e classificação para identificar a evasão discente, partindo dos dados da inscrição do estudante em um curso presencial. Ele conclui que os dados escolhidos conferem um baixo nível de precisão nos resultados.

Desse modo, este artigo tem o propósito de apresentar um sistema inteligente capaz de realizar a predição de grupos de risco de evasão discente em cursos superiores presenciais, inferido de maneira fidedigna sobre as condições dos estudantes quanto à evasão (Martinho, 2012). O sistema foi desenvolvido utilizando uma das técnicas da inteligência artificial, a Rede Neural ARTMAP-Fuzzy (Carpenter *et al.*, 1992a; Carpenter *et al.*, 1992b; Carpenter and Grossberg, 1992), que apresenta a possibilidade de treinamento continuado (Marchiori *et al.*, 2011).

Ressalta-se que, para além das singularidades já descritas deste sistema, frente aos trabalhos científicos sobre evasão, a pujança e a audácia desta pesquisa encontram-se na possibilidade de usar somente os dados da inscrição dos estudantes, para identificar precocemente a iminente evasão.

Após a introdução, na Seção 2 apresenta-se a delimitação da pesquisa e a construção da base de dados. As redes neurais ART e ARTMAP-Fuzzy são abordadas na Seção 3. Na Seção 4 descreve-se o desenvolvimento do sistema neural ARTMAP-Fuzzy proposto para a predição da evasão discente. A implementação do sistema, os resultados e as análises das simulações são apresentados na Seção 5. As considerações mais relevantes deste estudo estão na Seção 6.

2 Delimitação da Pesquisa e Construção da Base de Dados

Esta pesquisa foi desenvolvida com estudantes do Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso - IFMT, matriculados nos Cursos Superiores de Tecnologia (CST) em Automação Industrial e Controle, Controle de Obras e Sistemas para Internet. Os cursos abordados são de caráter presencial. Haja vista que o foco da investigação é o fenômeno da evasão escolar nos cursos presenciais do ensino superior.

Parte dos dados utilizados nesta pesquisa são as respostas dos questionários socioeconômicos, preenchidos pelos estudantes no ato da inscrição para o exame de seleção. Esses dados estão armazenados no Q-Seleção, um gerenciador de dados dos processos seletivos da instituição.

O questionário socioeconômico é composto por 23 questões, das quais 13 delas são selecionadas como características preditoras para a análise da evasão.

Além dos dados do questionário, são consideradas características como a distância entre a residência e a escola e o turno de estudo. Essas informações são coletadas no Q-Acadêmico, o gerenciador dos dados acadêmicos.

Os dados coletados para análise compreende um período de sete anos, de 2004/2 a 2011/2.

O vetor de entrada da rede neural é composto por 16 parâmetros e a saída da rede constituída por duas classes, evasão e não-evasão. Os pares de vetores entrada-saída desejada são representados na codificação binária. O vetor de entrada é composto por 41bits e, as saídas desejadas representadas por 1 bit.

Os nomes dos estudantes foram suprimidos para preservar sua identidade. Na planilha final são identificados com números (Martinho, 2012).

3 Redes Neurais ART-Fuzzy e ARTMAP-Fuzzy

No modelo ARTMAP-Fuzzy dois módulos ART estão interligados, através de um módulo inter-ART, denominado Mapa de Campo. Este módulo dispõe de um mecanismo autorregulador denominado *match tracking*, que busca casamentos entre as categorias dos módulos ART_a e ART_b, com objetivo de

elevar o grau de generalização e diminuir o erro da rede.

A rede neural ART-Fuzzy utiliza a teoria dos conjuntos nebulosos (Carpenter *et al.*, 1991), possibilitando o tratamento de padrões de entradas binários e analógicos, em um intervalo [0, 1], e aumentando a habilidade de generalização da rede.

3.1 Algoritmo de uma Rede Neural ART-Fuzzy

Consiste, fundamentalmente, na sequência abaixo, descrita a partir de Carpenter *et al.* (1991) e utilizada em Martinho *et al.* (2013).

I) Normalização dos dados de entrada

Os dados de entrada são representados pelo vetor $\mathbf{a} = [a_1 \ a_2 \ a_3 \ \dots \ a_M]$. A normalização desse vetor deve ser conforme (1):

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|}, \text{ sendo: } |\mathbf{a}| = \sum_i^M a_i \quad (1)$$

sendo:

$\bar{\mathbf{a}}$: vetor de entrada normalizado;

$|\mathbf{a}|$: norma do vetor de entrada \mathbf{a} ;

II) Codificação do vetor de entrada

É realizada, de acordo com (2), para preservar a amplitude da informação.

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (2)$$

sendo:

\bar{a}_i^c : elemento complementar do elemento do vetor de entrada normalizado;

$\bar{\mathbf{a}}^c$: vetor complementar da entrada normalizada.

Assim, o vetor de entrada da rede será o vetor \mathbf{I} , apresentado em (3).

$$\mathbf{I} = \begin{bmatrix} \bar{\mathbf{a}} & \bar{\mathbf{a}}^c \end{bmatrix} \quad (3)$$

III) Vetor de atividade

Indicado por $\mathbf{y} = [y_1 \ y_2 \ y_3 \ \dots \ y_N]$, sendo N o número de categorias criadas em F_2 . Assim, tem-se:

$$y_j = \begin{cases} 1, & \text{se o nó } j \text{ de } F_2 \text{ é ativo, se } j = J \\ 0, & \text{caso contrário, se } j \neq J \end{cases}$$

IV) Parâmetros da rede neural ART-Fuzzy

- Parâmetro de escolha ($\alpha > 0$) : atua na seleção de categorias da rede neural;
- Parâmetro de treinamento ($\beta \in [0, 1]$) : controla a taxa de treinamento e adaptação da rede;
- Parâmetro de vigilância ($\rho \in [0, 1]$) : controla a ressonância da rede.

V) Inicialização dos pesos

Inicialmente, todos os pesos possuem valores iguais a 1, como em (4):

$$w_{j1}(0) = w_{j2}(0) = \dots = w_{NM}(0) = 1 \quad (4)$$

VI) Escolha de uma categoria

A escolha da categoria j em F_2 atende à função de escolha T_j definida em (5):

$$T_j(\mathbf{I}) = \frac{|\mathbf{I} \wedge \mathbf{w}_j|}{\alpha + |\mathbf{w}_j|} \quad (5)$$

sendo: \wedge : operador AND Fuzzy, definido por (6):

$$(\mathbf{I} \wedge \mathbf{w})_i = \min(I_i, w_i) \quad (6)$$

O sistema escolhe a categoria correspondente ao nó J ativo, conforme (7):

$$J = \arg \max_{j=1, \dots, N} T_j \quad (7)$$

VII) Ressonância ou Reset

A ressonância ocorre se o critério de vigilância, (8), for satisfeito.

$$\frac{|\mathbf{I} \wedge \mathbf{w}_j|}{|\mathbf{I}|} \geq \rho \quad (8)$$

Se o critério de vigilância, (8), não for satisfeito, ocorre o *reset*.

VIII) Aprendizado (Atualização dos pesos)

Após o estado de ressonância, ocorre o processo de treinamento e aprendizado e, conseqüentemente, a modificação do vetor dos pesos, dada por (9).

$$\mathbf{w}_j^{\text{nov}} = \beta (\mathbf{I} \wedge \mathbf{w}_j^{\text{velho}}) + (1 - \beta) \mathbf{w}_j^{\text{velho}} \quad (9)$$

sendo:

J : categoria ativa;

$\mathbf{w}_j^{\text{nov}}$: vetor peso atualizado,

$\mathbf{w}_j^{\text{velho}}$: vetor peso referente à atualização anterior.

Se $\beta = 1$, tem-se o treinamento rápido.

3.2 Algoritmo de uma Rede Neural ARTMAP-Fuzzy

O processamento de uma rede neural ARTMAP-Fuzzy seguindo Carpenter *et al.* (1992b) e aplicado em Martinho *et al.* (2013), é mostrado abaixo:

I) Dados de entrada

Os vetores de entrada da rede ARTMAP-Fuzzy são representados por:

$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_p]$: entrada ART_a, amostra dos dados;

$\mathbf{b} = [b_1 \ b_2 \ \dots \ b_p]$: entrada ART_b, saída desejada;

sendo: P : o número de subvetores dos vetores \mathbf{a} e \mathbf{b} .

II) Matrizes de pesos

Todas as matrizes de pesos da rede são iniciadas com valores iguais a 1, mostrando que não existe nenhuma categoria ativa.

III) Parâmetros da rede

Os parâmetros usados no processamento da rede ARTMAP-Fuzzy são os mesmos usados na rede ART-Fuzzy. Porém cada módulo ART_a e ART_b rece-

be um padrão específico. A diferença é o parâmetro de vigilância do módulo Inter-ART ($\rho_{ab} \in [0, 1]$).

IV) Match tracking (busca de casamento)

Na rede neural ARTMAP-Fuzzy os módulos ART_a e ART_b, são processados e, após a ressonância ser confirmada em cada um deles, tem-se que:

- categoria ativa para o módulo ART_a : J
- categoria ativa para o módulo ART_b : K

Após a confirmação da ressonância em cada módulo é realizado o teste do *match tracking*, dado por (10):

$$\left| \mathbf{x}^{ab} \right|_i = \frac{\left| \mathbf{y}_i \wedge \mathbf{w}^{ab_j} \right|}{\left| \mathbf{y}_i \right|} \quad (10)$$

Pelo critério de vigilância, tem-se que:

Se, $\left| \mathbf{x}^{ab} \right|_i \geq \rho_{ab}$ - o par de treinamento deve

ser confirmado;

Se, $\left| \mathbf{x}^{ab} \right|_i < \rho_{ab}$ - deve-se buscar outro índice

J , até que o critério de vigilância seja satisfeito.

Se o critério de vigilância não for satisfeito, faz-se um pequeno incremento no parâmetro de vigilância do módulo ART_a, que se repetirá até que o critério de vigilância seja satisfeito.

V) Aprendizado (atualização dos pesos)

O aprendizado é realizado após ocorrer o estado de ressonância, procedendo-se a modificação do vetor peso, dada por (11) e (12), respectivamente, módulos ART_a e ART_b, e, por (13) e (14) módulo Inter-ART.

$$\mathbf{w}_j^a(\text{nov}) = \beta(\mathbf{I} \wedge \mathbf{w}_j^a(\text{velho})) + (1 - \beta) \mathbf{w}_j^a(\text{velho}) \quad (11)$$

$$\mathbf{w}_k^b(\text{nov}) = \beta(\mathbf{I} \wedge \mathbf{w}_k^b(\text{velho})) + (1 - \beta) \mathbf{w}_k^b(\text{velho}) \quad (12)$$

$$\mathbf{w}_{JK}^{ab(\text{nov})} = 0, \text{ para } k = 1, 2, \dots, N, \quad k \neq K \quad (13)$$

$$\mathbf{w}_{JK}^{ab(\text{nov})} = 1, \text{ para } k = 1, 2, \dots, N, \quad k = K \quad (14)$$

4 Sistema Neural ARTMAP-Fuzzy Proposto para Predição da Evasão

Nesta pesquisa, o modelo de sistema inteligente proposto foi desenvolvido utilizando uma rede neural ARTMAP-Fuzzy associada a um módulo da Lógica Fuzzy (Zadeh, 1965) e, em uma segunda simulação, um módulo que emprega a Teoria de Evidência de Dempster-Shafer - TDS (Barnett, 1981). Essa composição possibilitou identificar de maneira precoce, acurada e fidedigna o grupo de risco de evasão escolar discente, em cursos presenciais do ensino superior do IFMT, com uma base de dados extraída das informações no ato da inscrição do estudante para o exame de seleção.

A estrutura do sistema de predição proposto e a seqüência de desenvolvimento deste trabalho estão representadas no fluxograma da Figura 1.

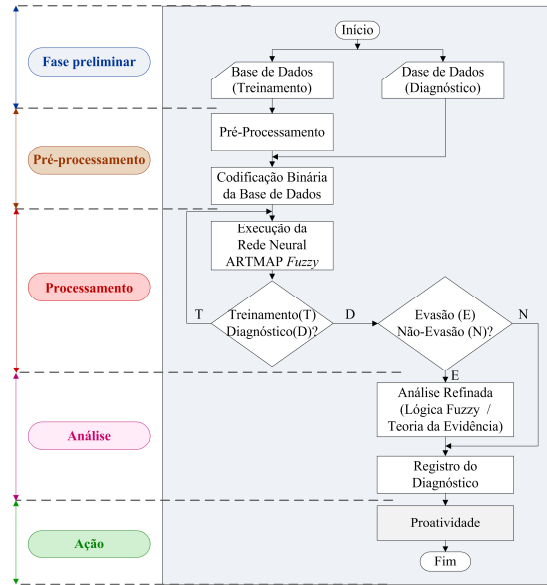


Figura 1. Fluxograma do processo de desenvolvimento do sistema neural proposto.

Na fase preliminar delimita-se a pesquisa, define-se o método e a base de dados.

Em seguida, na fase de pré-processamento, realiza-se a “limpeza” e a filtragem dos dados brutos selecionados, a categorização das características dos estudantes e o tratamento das informações, semelhante ao proposto por (Silveira, 2011). As bases de dados analógicas são convertidas em bases de dados binários (para o treinamento e para o diagnóstico). A concepção de um sistema neural essencialmente binário apresenta um comportamento mais eficiente, com maior rapidez e melhor precisão nas respostas, e permite a extração do conhecimento de forma contínua (Marchiori *et al.*, 2011), buscando uma melhor adaptação às condições da instituição e o aperfeiçoamento com o passar do tempo.

Após a binarização as informações são dispostas em linhas. Em cada linha estão contidas as características dos estudantes, que compõem o vetor de entrada (41 bits) da rede neural e representam uma amostra. A saída desejada da rede, também binária (1 bit), é formada pelo status do estudante (não evadiu (0) ou evadiu (1)) fornecido pela base de dados. Os vetores de entrada e saída desejada são apresentados às entradas dos módulos ART_a e ART_b, respectivamente, para o processamento das informações.

Concluído o processamento dos dados, chega-se à fase de interpretação, análise e avaliação dos resultados. Nessa fase, se na saída da rede neural a resposta em relação à evasão for negativa (classe “0”), nenhuma ação é adotada, apenas é realizado o registro da referida informação. Se a resposta de evasão for positiva (classe “1”), essa informação passa pelo módulo Fuzzy, para uma melhor discriminação sobre a qualidade da informação (análise fina).

O final do processo é a fase da Ação. Diante dos

resultados, propõe-se ações individualizadas (ação proativa), para atender as necessidades de cada estudante, proporcionando condições para sua permanência na instituição. Ressalta-se que a proatividade depende fortemente da atuação da instituição.

5 Aplicação e Análise dos Resultados

Nesse estudo, em específico, a entrada da rede ARTMAP-Fuzzy proposta é representada pelo vetor a (entrada ARTa) e sua respectiva saída desejada, na fase de treinamento, representada pelo vetor b (entrada ARTb), sendo estes descritos da seguinte maneira:

$a = [a_1 \ a_2 \ \dots \ a_{16}]$ e $b = [b]$, sendo: $b = "0"$ ou $"1"$

Os subvetores a_1, a_2, \dots, a_{16} do vetor a (Tabela 1) são vetores linhas que contêm a representação binária das características dos estudantes. Cada *bit* corresponde a um componente do vetor associado.

A saída da rede é representada pelo vetor atividade da camada F2 (y) e fornece respostas na codificação binária com 1 *bit* (Tabela 1), assim definido:

$y = [y]$ (saída da rede ARTMAP-Fuzzy)

Tabela 1. Composição dos Vetores de Entrada e Saída.

Características dos Subvetores de a e y				
	Posição	Nome	Abrev.	Tam.
Variáveis do Vetor de Entrada (a) da Rede	a_1	Sexo	Sx	1 bit
	a_2	Faixa etária	FxEt	3 bits
	a_3	Etnia	Etn	3 bits
	a_4	Estado Civil	EstCiv	3 bits
	a_5	Nº pessoas/casa	PesCs	3 bits
	a_6	Renda Familiar	Rfam	3 bits
	a_7	Tem Computador	Comp	1 bit
	a_8	Escolaridade pais	EscPais	3 bits
	a_9	Escola de Origem	EscOrig	3 bits
	a_{10}	Auto avaliação	AAval	3 bits
	a_{11}	Procedência	Procd	1 bit
	a_{12}	Dist. Esc.- Resid.	DistER	3 bits
	a_{13}	Meio Transporte	Transp	3 bits
	a_{14}	Situação Trabalho	Trab	3 bits
	a_{15}	Turno de Estudo	Turno	2 bits
	a_{16}	Alunos/ Sala	Al/Sl	3 bits
Vetor Saída (y)	y	Não-Evasão	NEv	1 bit
		Evasão	Ev	

Na fase de validação e diagnóstico do sistema neural ARTMAP-Fuzzy foram utilizadas, para este estudo, uma amostra do CST em Automação com 389 linhas e 41 colunas, cerca de 30% do total das amostras do treinamento. Os dados das colunas de 1 a 41 representam os atributos correspondentes ao vetor a , entrada do módulo ARTa. Na coluna 42 estão representadas as saídas desejadas, vetor b (entrada ARTb) da rede neural ARTMAP-Fuzzy.

Os parâmetros utilizados no processamento dos dados estão especificados na Tabela 2. Os parâmetros apresentados foram os que proporcionaram o melhor desempenho do sistema, definidos através do

resultado das simulações.

Tabela 2 - Especificação dos parâmetros da rede neural ARTMAP-Fuzzy.

Parâmetros e Valores de Referência	
Parâmetros	Valores
Parâmetro de escolha ($\alpha > 0$)	0,001
Taxa de treinamento ($\beta \in [0,1]$)	1,0
Parâmetro de vigilância módulo ART _a ($\rho_a \in [0,1]$)	0,2
Incremento do parâmetro de vigilância ρ_a (ϵ)	0,05
Parâmetro de vigilância módulo ART _b ($\rho_b \in [0,1]$)	0,999
Parâmetro de vigilância módulo inter-ART _{ab} ($\rho_{ab} \in [0,1]$)	0,7
Parâmetro de vigilância no <i>match tracking</i> ($\rho_{amat} \in [0,1]$)	0,75

Após o treinamento da rede foram realizadas cinco simulações, com a base de dados para o diagnóstico, para a validação do modelo proposto.

Os resultados das simulações foram comparados e analisados, utilizando-se o “critério de votação” [Carpenter *et al.*, 1992b], foi verificada a saída “0” ou “1” de maior incidência para cada uma das entradas. O resultado de maior incidência constituiu-se na saída da rede neural.

Concluída a etapa do processamento através do sistema neural ARTMAP-Fuzzy e das análises pertinentes à compreensão do comportamento da rede quanto à evasão discente, os resultados foram compilados e, sucintamente, demonstrados na Tabela 3.

Tabela 3 - Resultado do diagnóstico da evasão discente: evasão total no período de 2004-2010 – CST em Automação.

Diagnóstico Evasão Total	Saída Rede - Valores Quantitativos e Percentuais					
	Evasão		Não-Evasão		Total Amostras	
	Qtd.	%	Qtd.	%	Qtd.	%
2004/2010						
Amostras	243	100	146	100	389	100
Acertos	231	95,1	135	92,5	366	94,1
Erros	12	4,9	11	7,5	23	5,9

A interpretação e análise dos resultados demonstra que o sistema identificou 231 possibilidades de evasão e ignorou 12, de um total de 243 estudantes evadidos, obtendo um índice de acerto de 95,1%. Dentre as 146 amostras de estudantes não evadidos, 135 foram reconhecidas, acertando 92,5% dos casos. Nesta simulação, o sistema neural ARTMAP-Fuzzy alcançou um percentual de acerto global de 94,1%.

Os resultados quantitativos e em percentuais do diagnóstico de evasão podem ser percebidos, com maior clareza, nos gráficos da Figura 2.

Em outra simulação, em que se considerou apenas os estudantes evadidos no 1º semestre do curso, no período de 2004 a 2011. Obteve-se um índice de acerto de 97,8% com relação aos estudantes evadidos e um percentual de acerto global de 76,7% (Martinho *et al.*, 2013), corroborando os índices de acurácia do sistema proposto.

Considerando os testes realizados e a consistência dos resultados obtidos, pode-se inferir que o sistema inteligente proposto, utilizando rede neural ARTMAP-Fuzzy, é um modelo com significativo grau de confiabilidade e exprime fidedignamente a

situação que se encontra os estudantes analisados.

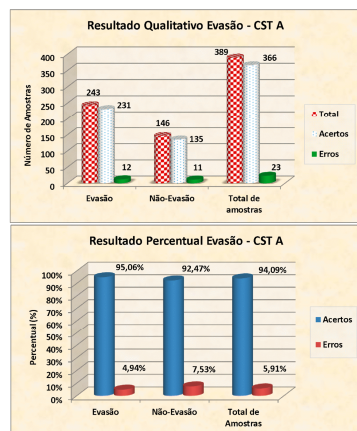


Figura 2 - Resultado quantitativo e percentual da predição da evasão total em CST-2004 a 2010.

6 Considerações Finais

Este trabalho está alicerçado em uma pesquisa que tem como objetivo propor um método inovador para identificar, de maneira proativa, continuada e acurada os estudantes considerados do grupo de risco de evasão discente, em cursos superiores presenciais, com uma base de dados composta pelas informações da inscrição. Para esse propósito foi implementado um sistema neural ARTMAP-Fuzzy associado com um módulo Fuzzy e um módulo da Teoria de Evidência de Dempster-Shafer.

Com a análise dos resultados obtidos é possível inferir que o sistema proposto é robusto, eficaz e com significativo grau de confiabilidade, alcançou um índice de acerto global entre 76% e 94% na identificação antecipada do grupo de risco de evasão.

O confronto dos resultados obtidos neste estudo com aqueles descritos por (Mustafa *et al.*, 2012), com a aplicação de árvores de decisão (entre 28% e 38% de acertos), para identificar a evasão com base nos dados da inscrição dos estudantes, demonstra a qualidade e relevância do sistema neural ARTMAP-Fuzzy proposto.

Portanto, evidencia-se que o do sistema neural ARTMAP-Fuzzy é uma poderosa, arrojada e inovadora ferramenta para a predição de grupos de risco de evasão discente, em cursos superiores presenciais, inserindo-se na lacuna existente nas produções da comunidade científica mundial, no que tange o tema em questão, contribuindo desta forma com algo que seja útil para a sociedade. Pois, com uma ação proativa, conseguir com que um estudante, com potencial de evadir, tenha sucesso é uma missão nobre.

Agradecimentos

Ao Instituto Federal de Mato Grosso pela disponibilização das bases de dados para essa pesquisa, bem como, a CAPES pelo apoio financeiro.

Referências Bibliográficas

- Barbosa, J. O. (2010). Identificação e Análise dos Fatores Preponderantes e Determinantes da Evasão Escolar no CST em Automação Industrial no IFMT - 2004-2010. Relatório Interno, 40 p.
- Barnett, J. A. (1981). Computational Methods for a Mathematical Theory of Evidence. Proceedings of the 7th International Joint Conference on Artificial Intelligence. Vancouver.
- Carpenter, G. A. and Grossberg, S. (1992). A Self-Organizing Neural Network for Supervised Learning, Recognition, and Prediction. Communications Magazine, vol. 30, pp. 38-49.
- Carpenter, G. A.; Grossberg, S. and Iizuka, K. (1992a). Comparative Performance Measures of Fuzzy ARTMAP, Learned Vector Quantization, and Back Propagation for Handwritten Character Recognition. International Joint Conference on Neural Networks - IJCNN. vol.1, pp. 794-799.
- Carpenter, G. A.; Grossberg, S. and Rosen, D. B. (1991). Fuzzy ART: Fast Stable Learning and Categorization of Analog Patterns by an Adaptive Resonance System. Neural Network, vol. 4, pp. 759-771.
- Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. and Rosen, D. B. (1992b). Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. Neural Networks, IEEE Transactions on, vol. 3, pp. 698-713.
- Haykin, S. S. (2009). Neural Networks and Learning Machines. Prentice Hall. 906p.
- Lykourentzou, I.; giannoukos, I.; nikolopoulos, V. et al. (2009). Dropout Prediction in E-Learning Courses through the Combination of Machine Learning Techniques. Journal Computers & Education, vol. 53, n.º. 3, pp. 950-965.
- Marchiori, S. C.; Silveira, M. C. G. da; Minussi, C. R. et al. (2011). Neural Network Based on Adaptive Resonance Theory with Continuous Training for Multi-Configuration Transient Stability Analysis of Electric Power Systems. Applied Soft Computing, vol. 11, pp. 706-715.
- Martinho, V. R. C. (2012). Sistema Inteligente para Predição do Grupo de Risco de Evasão Discente. UNESP, Faculdade de Engenharia. 58p.
- Martinho, V. R. C.; Nunes, C. and Minussi, C. R. (2013). A New Method for Prediction of School Dropout Risk Group Using Neural Network Fuzzy. 15th ICAI'2013. Las Vegas, USA: Proceedings of the ICAI'13. (no prelo)
- Mustafa, M. N.; Chowdhury, L. and Kamal, S. (2012). Students Dropout Prediction for Intelligent System from Tertiary Level in Developing Country. International Conference on Informatics, Electronics & Vision. Dhaka, Bangladesh: IEEE.
- Nilsson, N. J. (1998). Artificial Intelligence: A New Synthesis, Morgan Kaufman Publ Incorporated.
- Silveira, M. C. G. (2011). Sistema de Gerenciamento de Base de Dados para Aplicação em Ambientes de Sistemas Elétricos de Potência. UNESP, Departamento de Engenharia Elétrica.
- Zadeh, L. A. (1965). Fuzzy Sets. Information and Control, vol. 8, n.º. 3, pp. 338-353.