

# Um Novo Método para Predição da Evasão Escolar Usando Redes Neurais

Valquíria R. C. Martinho, Clodoaldo Nunes, Carlos R. Minussi.

Laboratório de Sistemas Inteligentes - SINTEL, Departamento de Engenharia Elétrica  
Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista – UNESP  
Ilha Solteira - SP, Brasil  
[vribeiro@terra.com.br](mailto:vribeiro@terra.com.br) , [cncefet@gmail.com](mailto:cncefet@gmail.com) , [minussi@dee.feis.unesp.br](mailto:minussi@dee.feis.unesp.br)

**Abstract**—Dropping out of school is one of the most complex and crucial problems in education. Worldwide, the phenomenon afflicts and concerns everyone involved, from basic education to higher education, both public and private, causing social, economic, political, academic and financial losses. 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 perspective, this paper presents the potentials of an intelligent, bold and innovative system, developed for the prediction of risk groups of student dropout in higher education classroom using a Fuzzy ARTMAP Neural Network, one of the techniques of artificial intelligence, with the possibility of continued learning. 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 97% 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**—higher education, school dropout, prediction dropout, artificial neural networks (ANN), Art Family, Fuzzy ARTMAP neural network.

## I. INTRODUÇÃO

Historicamente, a evasão escolar é um dos problemas mais complexos e cruciais no âmbito da educação. Ela gera prejuízos sociais, econômicos, políticos, acadêmicos e financeiros a todos os envolvidos no processo educativo, desde o estudante até os órgãos governamentais e de fomento, que anseiam por estratégias eficazes para reduzir os índices da evasão escolar, haja vista que as medidas adotadas até então não surtiram o efeito desejado.

No que tange ao ensino superior, a evasão escolar é um problema internacional. Apesar de seus índices apresentarem variações consideráveis entre diferentes nações, eles demonstram que na atualidade a evasão escolar está presente e assola cada vez mais um número maior de instituições de ensino superior (IES) no mundo.

A propósito, pode-se mencionar os Estados Unidos - EUA, com taxa de evasão nas faculdades e universidades em torno de 40%, representando um declínio no índice de estudantes graduados no ensino superior [1]. Em contrário, China e Índia, potencializam o ensino superior, aumentando o índice de conclusão [2]. Entre estes extremos situa-se o Brasil, apresentando um índice médio de evasão em torno de 20% [3, 4].

Resguardando todas as diferenças e especificidades das IES de diferentes nações, ainda assim, existe um ponto de convergência entre elas, a árdua tarefa de solucionar o problema da evasão [5].

Nessa perspectiva, programas de prevenção e intervenção são desenvolvidos e estruturados levando-se em consideração os resultados de pesquisas que identificam as possíveis causas que geram o fenômeno da evasão. Porém, tais medidas poderiam ser mais profícuas se houvesse o conhecimento prévio dos estudantes propensos à evasão. E, para isso, faz-se necessário o desenvolvimento de métodos, instrumentos ou sistemas capazes de previamente fazer essa identificação.

Ao encontro dessa necessidade foi desenvolvido um sistema inteligente, arrojado e inovador, para a predição de grupos de risco de evasão discente, em cursos superiores presenciais [6], utilizando técnicas da inteligência artificial, a Rede Neural ARTMAP-Fuzzy [7-9]. Esta rede possui uma arquitetura em que o treinamento é realizado de modo supervisionado e auto-organizável, com possibilidade de aprendizado continuado [7].

Este artigo tem como objetivo apresentar e disponibilizar o sistema inteligente desenvolvido, como possibilidade de identificar, de maneira proativa, continuada e acurada os estudantes, da educação clássica-presencial, propensos à evasão no ensino de nível superior. E, também, socializar seus profícuos resultados que contribuíram para elaboração de programas de prevenção e intervenção, individualizada, visando a permanência desses estudantes identificados na instituição de ensino [6].

Na sequência, este estruturado da seguinte maneira: Seção 2 - as publicações consideradas mais relevantes para esta proposta. Seção 3 - as redes ART e ARTMAP-Fuzzy e seus algoritmos de treinamento. Seção 4 - a área de estudo, a construção da base de dados e o desenvolvimento do sistema inteligente em questão. Seção 5 - a implementação do sistema. Seção 6 - os resultados e as análises dos testes efetuados. Seção 7 - as conclusões mais relevantes do experimento.

## II. BREVE REVISÃO

Na literatura, encontram-se poucas referências que analisam a evasão escolar através da utilização de redes neurais artificiais e, um número ainda menor de trabalhos aplicando, especificamente, da rede neural ARTMAP-Fuzzy no estudo desse fenômeno.

A maioria das pesquisas analisam as causas da evasão. São produções teóricas e críticas e apresentam como resultados os fatores que mais influenciam na evasão escolar no ensino superior brasileiro, suas consequências e possíveis caminhos de superação [10]. Através delas percebe-se a situação da educação no Brasil,

delineada com dados estatísticos de escolas públicas, privadas e de pesquisa de órgãos governamentais [11]. Numa visão mais global, tem-se modelos teóricos com esquemas explicativos sobre as causas da evasão [12], além de estudos comparativos entre países com educação precária e com índice de evasão insignificante [13] e, também, estudos com estudantes que mudam constantemente de escolas, demonstrando causas semelhantes para que ocorra a evasão [14].

Em menor escala, encamtram-se produções científicas que se propõem a analisar e prever a evasão escolar utilizando sistemas inteligentes, dentre as técnicas empregadas estão a mineração de dados (Data Mining) [15-17] e as Redes Neurais Artificiais [18-21], invariavelmente a rede Perceptron multicamadas (MLP). Em todas as pesquisas analisadas, os resultados auferidos foram: a identificação de padrões descritivos causais que levam os estudantes ao abandono da escola e a constatação da eficiência e desempenho das técnicas empregadas. Além dos cursos presenciais, foram investigadas as variáveis que podem influenciar a evasão de estudantes em cursos de ensino à distância.

Considerando os trabalhos nesta área, destaca-se como relevantes para o estudo desta pesquisa, o trabalho [22] que investiga o grupo de risco de estudantes com propensão à evasão em cursos e-learning, utilizando a combinação de três técnicas de aprendizagem de máquina, entre elas a rede neural ARTMAP-Fuzzy e, a referência [23] que utiliza árvores de regressão e classificação para identificar a evasão discente, partindo dos dados da inscrição do estudante em um curso presencial. Este estudo conclui que os dados escolhidos conferem um baixo nível de precisão nos resultados. O sistema apresentado neste artigo demonstra resultados satisfatórios, acertos globais em torno de 76%, comparado com outros trabalhos que utilizaram bases de dados semelhantes.

### III. REDES NEURAIS ART E ARTMAP-FUZZY

As Redes Neurais Artificiais (RNA) [20] são modelos matemáticos computacionais que emulam o cérebro humano e aprendem com a experiência, tentando modelar e simular o seu processo de aprendizagem, organizando seus neurônios de forma que sejam capazes de processar as informações.

Uma rede neural típica consiste de vários neurônios, arrançados em camadas adjacentes, conectados por sinapses (canais de comunicação) associados a determinados pesos atribuídos às conexões entre os neurônios, onde está armazenado todo conhecimento de uma RNA. Possuem sempre uma camada de entrada e uma camada de saída, podendo ter entre elas um número variável de camadas, denominadas camadas ocultas ou intermediárias.

O uso de redes neurais oferece alguns benefícios e capacidades, que em síntese são: não-linearidade, mapeamento entrada-saída, adaptabilidade (“dilema da estabilidade-plasticidade”), resposta a evidências, informação contextual, tolerância a falhas, uniformidade de análise, analogia neurobiológica.

Os sistemas de redes ART são capazes de resolver o dilema “estabilidade-plasticidade”. Eles são plásticos, pois são capazes de aprender a se adaptar em um ambiente em mudança e, ao mesmo tempo, preservam seus conhecimentos aprendidos anteriormente, mantendo sua capacidade para aprender novos padrões, portanto são estáveis.

O modelo ARTMAP-Fuzzy associa dois módulos ART (não-

supervisionados) em uma estrutura de aprendizado supervisionado, onde a primeira unidade recebe os dados de entrada e a segunda unidade recebe os dados das saídas desejadas [24]. Os módulos ART estão interligados através de um módulo inter-ART, denominado Mapa de Campo. Este dispõe de um mecanismo autorregulador denominado *match tracking*, que busca casamentos ou combinações entre as categorias dos módulos ART<sub>a</sub> e ART<sub>b</sub>, tendo como objetivo elevar o grau de generalização e diminuir o erro da rede.

A rede neural ART-Fuzzy utiliza a teoria dos conjuntos nebulosos [25], empregando o operador de mínimo ( $\wedge$ ) AND Fuzzy, possibilitando o tratamento de padrões de entradas binários e analógicos, em um intervalo [0, 1], e aumentando a habilidade de generalização da rede.

#### A. Algoritmo de uma Rede Neural ART-Fuzzy

O algoritmo de uma rede neural ART-Fuzzy consiste, fundamentalmente, na sequência descrita a seguir [25]:

##### 1) 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  $\mathbf{a}$ ;

$a_i$  : elemento do vetor de entrada  $\mathbf{a}$  com índice  $i$ .

##### 2) Codificação do vetor de entrada

A codificação por seu complemento 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).

$$\mathbf{I} = \left[ \bar{\mathbf{a}} \quad \bar{\mathbf{a}}^c \right] \quad (3)$$

$$\mathbf{I} = \left[ \bar{a}_1 \quad \bar{a}_2 \quad \dots \quad \bar{a}_M \quad \bar{a}_1^c \quad \bar{a}_2^c \quad \dots \quad \bar{a}_M^c \right]$$

##### 3) Vetor de atividade

O vetor de atividade da camada de reconhecimento  $F_2$  é 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 que:

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

##### 4) Parâmetros da rede neural ART-Fuzzy

Três parâmetros são essenciais no processamento da rede ART-Fuzzy, são eles:

- 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.

#### 5) Inicialização dos pesos

Inicialmente, todos os pesos possuem valores iguais a 1, como em (4), indicando que não existe nenhuma categoria ativa:

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

#### 6) Escolha de uma categoria

Considerando um vetor de entrada  $\mathbf{I}$  em  $F_1$ , 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):

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

Se existir mais de um neurônio com ativação máxima, a categoria escolhida será aquela que possuir o menor índice  $j$ .

#### 7) 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*. No *reset*, o nó  $J$  de  $F_2$  é excluído do processo de busca. Então, é escolhida uma nova categoria através da aplicação de (7) para a realização do processo de ressonância. Este procedimento é realizado até que a rede encontre uma categoria que satisfaça (8).

#### 8) Aprendizado (Atualização dos pesos)

Após o vetor de entrada  $\mathbf{I}$  ter completado o estado de ressonância, ocorre o processo de treinamento e aprendizado e, conseqüentemente, a modificação do vetor dos pesos, dada por (9).

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

sendo:

$J$  : categoria ativa;

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

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

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

### B. Algoritmo de uma Rede Neural ARTMAP-Fuzzy

O algoritmo para o processamento de uma rede neural ARTMAP-Fuzzy [8], ocorre da seguinte maneira:

#### 1) Dados de entrada

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

- $\mathbf{a} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \dots \ \mathbf{a}_p]$ : entrada ART<sub>a</sub>, amostra dos dados;
- $\mathbf{b} = [\mathbf{b}_1 \ \mathbf{b}_2 \ \dots \ \mathbf{b}_p]$ : entrada ART<sub>b</sub>, saída desejada;

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

#### 2) Matrizes de pesos

As matrizes de pesos associadas aos módulos ART<sub>a</sub> (matriz  $\mathbf{w}^a$ ) e ART<sub>b</sub> (matriz  $\mathbf{w}^b$ ), bem como ao módulo Inter-ART (matriz  $\mathbf{w}^{ab}$ ), são iniciadas com valores iguais a 1, tendo em vista que todas as atividades encontram-se inativas.

#### 3) Parâmetros da rede

Os parâmetros usados no processamento da rede ARTMAP-Fuzzy são os mesmos usados na rede ART-Fuzzy. Porém cada módulo ART<sub>a</sub> e ART<sub>b</sub> recebe um padrão específico. Além destes, existe o parâmetro de vigilância do módulo Inter-ART, sendo:  $\rho_{ab} \in [0, 1]$ .

#### 4) Match tracking (busca de casamento)

Na rede neural ARTMAP-Fuzzy os módulos ART<sub>a</sub> e ART<sub>b</sub>, são processados e, após a ressonância ser confirmada em cada um deles, tem-se que:

- categoria ativa para o módulo ART<sub>a</sub> :  $J$
- categoria ativa para o módulo ART<sub>b</sub> :  $K$

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

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

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<sub>a</sub>, que se repetirá até que o critério de vigilância seja satisfeito.

#### 5) Aprendizado (atualização dos pesos)

Somente após ocorrer o estado de ressonância, o processo de treinamento e aprendizado é realizado, acontecendo a modificação do vetor peso, dada por (11) e (12), respectivamente, módulos ART<sub>a</sub> e ART<sub>b</sub> e, por (13) e (14) módulo Inter-ART.

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

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

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

$$\mathbf{w}^{ab} JK^{\text{nov}} = 1 \quad (14)$$

As operações definidas na atualização dos pesos consistem em uma versão específica da rede ARTMAP-Fuzzy implementada neste trabalho, sendo definidas e descrita para dados binários.

#### IV. METODOLOGIA

Este estudo foi realizado no âmbito do Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso - IFMT. O universo de interesse são os estudantes matriculados nos Cursos Superiores de Tecnologia (CST) em Automação e Controle Industrial, Controle de Obras, Sistema para Internet, Redes de Computadores e Secretariado Executivo, do IFMT, de caráter presencial e dos períodos matutino, vespertino e noturno. A escolha se justifica tendo em vista os altos índices de evasão nos mesmos, constatado através de levantamentos estatísticos prévios, haja vista o CST em Automação e Controle Industrial, que atingiu um índice de 62,46% de evasão no período de 2004-2010 [6].

Na implantação e teste piloto do sistema inteligente proposto, a rede neural foi alimentada com os dados de todos os estudantes matriculados nos CST, no período de 2004 a 2009, perfazendo um total de 1650 amostras para a fase de treinamento, constituindo-se na base de dados histórica. Para o diagnóstico foram usadas 499 amostras, compostas com os dados dos matriculados em 2010 e 2011 [6].

A base de dados para predição do grupo de risco propenso a evasão é constituída por características dos estudantes que compreendem fatores demográficos, fatores internos e externos à escola. Para o levantamento dessas características foi utilizada a base de dados dos processos seletivos do IFMT, o Q-Seleção, que armazena as respostas do questionário socioeconômico preenchido pelos estudantes no ato da inscrição para o exame de seleção. E, o Q-Acadêmico, sistema de gestão acadêmica integrada, onde se concentra toda história acadêmica dos estudantes do IFMT [6]. Ressalta-se que a base de dados não contém os nomes dos estudantes, os quais são identificados, apenas, por números.

O vetor de entrada da rede neural ARTMAP-Fuzzy é composto por 16 parâmetros considerados como significativos para a predição da evasão escolar 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, sendo o vetor de entrada composto por 41bits e, as respostas previstas representadas por 1 bit. Uma síntese das variáveis de entrada e saída da rede neural pode ser visualizada na Tabela I.

TABELA I. 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/SI	3 bits
Vetor Saída ( $y$ )	$y$	Não-Evasão	NEv	1 bit
		Evasão	Ev	

#### V. SISTEMA NEURAL ARTMAP-FUZZY PROPOSTO PARA PREDIÇÃO DA EVASÃO

Os dados que envolvem o estudo sobre evasão, são por vezes, complexos, subjetivos, não-lineares, inter-relacionados e guardam em si as especificidades inerentes aos diferentes níveis de ensino, cursos e instituições que se possa analisar. Desta maneira, optou-se em utilizar as RNA, pois, dentre suas potencialidades tem-se a possibilidade de processar problemas onde relações complexas e desconhecidas estão envolvidas entre diferentes conjuntos de dados e, também, ajustar as relações de não-linearidade entre as variáveis de entrada e de saída [6]. Mais especificamente, a rede ARTMAP-Fuzzy, onde o treinamento é realizado de modo supervisionado e auto-organizável, com possibilidade de aprendizado continuado, como implementado em [26]. Seu potencial de aplicação destina-se a resolver vários problemas de classificação e de aproximação de funções não-lineares, apresentando rapidez de resposta.

A entrada da rede ARTMAP-Fuzzy proposta é representada pelo vetor  $a$  (entrada do módulo ART<sub>a</sub>) e sua respectiva saída desejada, na fase de treinamento, representada pelo vetor  $b$  (entrada do módulo ART<sub>b</sub>), sendo estes descritos da seguinte maneira:

$$a = [a_1 \ a_2 \ a_3 \ \dots \ a_{16}]$$

$$b = [b] \quad , \quad \text{sendo: } b = \text{"0"} \text{ ou "1"}$$

Os subvetores  $a_1, a_2, a_3, \dots, a_{16}$  do vetor  $a$  (Tabela I) 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  $F_2$  ( $y$ ) e fornece respostas na codificação binária com 1 bit, sendo que o código "1" corresponde à evasão e o código "0" a não-evasão discente, assim definido:

$$y = [y] \quad (\text{saída da rede ARTMAP-Fuzzy})$$

O modelo proposto, neste trabalho, consiste em um sistema inteligente (fluxograma mostrado na Fig. 1) destinado ao estudo da evasão discente no IFMT, empregando uma rede neural ARTMAP-Fuzzy [7-9], Lógica Fuzzy [27] e/ou Teoria de Evidência de Dempster-Shafer - TDS [28].

As informações da base de dados são pré-processadas e convertidas em uma base de dados binários. A concepção essencialmente binária é consideravelmente vantajosa, pois a rede neural apresenta um comportamento mais eficiente (rapidez e melhor qualidade das respostas) e permite a extração do conhecimento de forma contínua (treinamento continuado), buscando uma melhor adaptação às condições da instituição e o aperfeiçoamento com o passar do tempo.

Na fase da análise neural, se a resposta for negativa em relação à evasão, nenhuma ação é adotada, apenas é realizado o registro da referida informação. Se a resposta de evasão for positiva, o passo seguinte corresponde a uma melhor discriminação sobre a qualidade da informação (análise fina) baseado no emprego de um módulo Fuzzy e/ou da Teoria de Evidência de Dempster-Shafer. Posteriormente, serão propostas soluções que visem reverter a evasão discente (ação proativa).

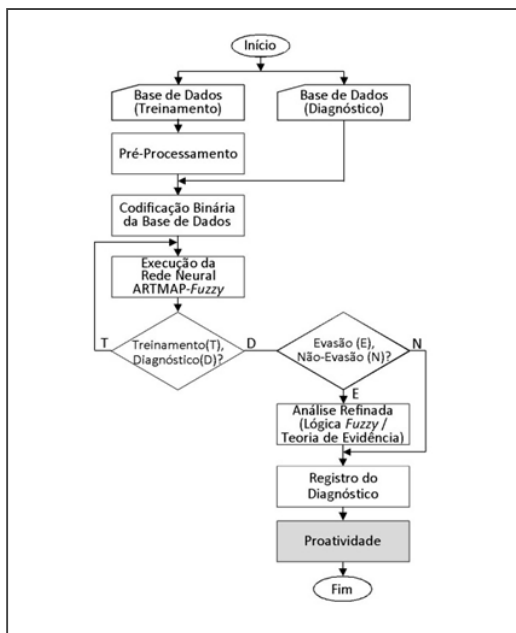


Fig. 1. Fluxograma do sistema neural proposto.

## VI. APLICAÇÃO E ANÁLISE DOS RESULTADOS

O sistema inteligente, utilizando uma Rede Neural ARTMAP-Fuzzy, proposto para realizar a predição do grupo de risco de estudantes propensos à evasão, foi implementado e testado com uma base de dados composta por 1.650 linhas e 42 colunas na fase do treinamento da rede. Na fase de validação e diagnóstico foi utilizada uma amostra com 499 linhas e 41 colunas, cerca de 30% do total das amostras do treinamento. Cada linha representa os vetores padrão de entrada e sua respectiva saída desejada, no treinamento. Os dados das colunas de 1 a 41 representam os atributos correspondentes ao vetor  $a$ , entrada do módulo ART<sub>a</sub>. Na coluna 42 estão representadas as saídas desejadas, vetor  $b$  (entrada do módulo ART<sub>b</sub>) da rede neural ARTMAP-Fuzzy.

Os parâmetros utilizados no processamento da base de dados estão especificados na Tabela II. Neste artigo estão apresentados os parâmetros que proporcionaram o melhor desempenho do sistema, definidos através do resultado de simulações.

TABELA II. ESPECIFICAÇÃO DOS PARÂMETROS: REDE 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 <sub>a</sub> ( $\rho_a \in [0,1]$ )	0,2
Incremento do parâmetro de vigilância $\rho_a$ ( $\epsilon$ )	0,05
Parâmetro de vigilância módulo ART <sub>b</sub> ( $\rho_b \in [0,1]$ )	0,999
Parâm. vigilância módulo inter-ART <sub>ab</sub> ( $\rho_{ab} \in [0,1]$ )	0,7
Parâm. vigilância no match tracking ( $\rho_{amat} \in [0,1]$ )	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, sendo que, em uma delas as amostras foram processadas na ordem natural que se apresentam os dados e nas demais de forma randômica.

Os resultados dos processamentos foram comparados e

analisados, utilizando-se um critério, denominado “critério de votação” [8], 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.

Posteriormente, confrontando a saída resultante da rede com a real situação de cada amostra do grupo de estudante analisado, foi possível averiguar a coincidência de evasão (“1”) e não evasão (“0”) entre as amostras processadas e a realidade.

Concluída as etapas do processamento dos bancos de dados através de uma Rede Neural ARTMAP-Fuzzy e das análises pertinentes e necessárias à compreensão do comportamento da rede quanto à evasão e não evasão discente, os resultados foram compilados e, sucintamente, demonstrados na Tabela III.

TABELA III. RESULTADOS QUANTITATIVOS E PERCENTUAIS DO DIAGNÓSTICO DA PREDIÇÃO DA EVASÃO ESCOLAR.

Diagnóstico da Evasão Escolar	Valores Quantitativos e Percentuais: Saída da Rede					
	Evasão		Não-Evasão		Total de Amostras	
	Qtd.	%	Qtd.	%	Qtd.	%
Amostras	90	100	409	100	499	100
Acertos	88	97,8	295	72,1	383	76,7
Erros	2	2,2	114	27,9	116	23,3

A leitura, interpretação e análise dos dados contidos na Tabela 3 mostram que:

- do total de 499 amostras, 90 delas correspondiam a estudantes evadidos e, 409 estudantes já graduados ou em curso, ou seja, não evadidos.
- das 90 amostras de evasão, o sistema proposto identificou 88 possibilidades de evasão e ignorou 2, obtendo um índice de acerto de 97,8%.
- dentre as 409 amostras de não-evasão, a rede ARTMAP-Fuzzy proposta reconheceu 295 amostras nessa situação e não atingiu o alvo em 114, acertando 72,1% dos casos.
- alcançou um percentual de acerto global de 76,7%, encontrando corretamente 383 amostras de um total de 499.

Os resultados quantitativos e em percentuais do diagnóstico prévio de estudantes com possibilidades de evasão podem ser percebidos, com maior clareza, nos gráficos da Fig. 2 e Fig. 3, respectivamente.




Fig. 2. Resultado quantitativo da predição da Evasão.

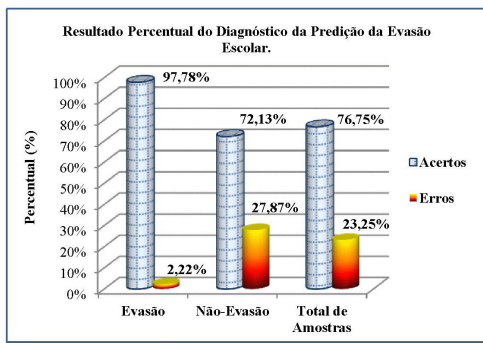


Fig. 3. Resultado percentual da predição da evasão.

Considerando o experimento realizado e a consistência dos resultados obtidos, pode-se inferir que o sistema inteligente, utilizando rede neural ARTMAP-Fuzzy, proposto para identificar os estudantes propensos à evasão, é um modelo com significativo grau de confiabilidade e exprime fidedignamente a situação que se encontra os estudantes analisados.

## VII. CONCLUSÃO

Neste trabalho foi apresentado um método inovador para identificar, de maneira proativa, continuada e acurada os estudantes considerados do grupo de risco de evasão escolar, usando rede neural ARTMAP-Fuzzy.

A análise dos resultados obtidos demonstrou que o sistema proposto é satisfatório, com acerto global superior a 76%, e com significativo grau de confiabilidade, possibilitando identificar precocemente, ainda no primeiro semestre do curso, o grupo de estudantes em risco de evasão.

O confronto dos resultados obtidos neste estudo com aqueles descritos por Mustafa [23], 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.

O sistema proposto, utilizando Rede Neural ARTMAP-Fuzzy apresenta como vantagem a possibilidade de se trabalhar com um conjunto de dados complexos, bem como a inserção de novos padrões de treinamento sem a necessidade de reiniciar o processo, tendo em vista sua característica de plasticidade, possibilitando assim um aprendizado continuado.

Portanto, diante dos resultados alcançados com o experimento, evidencia-se que o método proposto 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.

## AGRADECIMENTO

Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso - IFMT - Campus Cuiabá, pela disponibilização da base de dados dos sistemas acadêmico e de seleção, bem como, a CAPES pelo apoio financeiro.

## REFERÊNCIAS

[1] T. Ross, G. Kena, A. Rathbun, A. Kewalramani, J. Zhang, P. Kristapovich, and E. Manning, "Higher Education: Gaps in Access and Persistence Study" U.S. Department of Education, Washington DC, Statistical Analysis Report NCES 2012-046, Aug 2012.

[2] N. Gier, "The Crisis in Idaho Higher Education: A Lack of Faculty Autonomy as well as Funding," in Idaho State Journal, Idaho - USA, 2009.

[3] R. L. L. Silva Filho and M. B. d. C. M. Lobo, "Como a Mudança na Metodologia do INEP altera o Cálculo da Evasão," Instituto Lobo para o Desenvolvimento da Educação, da Ciência e da Tecnologia, SP, abr 2012.

[4] Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira - INEP, "Censo da educação superior: 2010 - resumo técnico," INEP, Brasília - DF, 2012.

[5] UNESCO, "Tendências para a Educação Superior no Século XXI," in: *Conferência Mundial da UNESCO sobre Educação Superior no Século XXI: Visão e Ação* Paris, 1998, p. 23.

[6] V. R. C. Martinho, "Sistema Inteligente para Predição do Grupo de Risco de Evasão Discente," Exame Geral de Qualificação (Doutorado em Engenharia Elétrica), Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Estadual Paulista - UNESP, Ilha Solteira - SP, 2012.

[7] G. A. Carpenter, S. Grossberg, and K. Iizuka, "Comparative performance measures of fuzzy ARTMAP, learned vector quantization, and back propagation for handwritten character recognition," in: *Neural Networks, 1992. IJCNN., International Joint Conference on*, 1992, pp. 794-799 vol.1.

[8] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps," *Neural Networks, IEEE Transactions on*, vol. 3, pp. 698-713, 1992.

[9] G. A. Carpenter and S. Grossberg, "A self-organizing neural network for supervised learning, recognition, and prediction," *Communications Magazine, IEEE*, vol. 30, pp. 38-49, 1992.

[10] C. A. S. Baggi, "Evasão e avaliação institucional: uma discussão bibliográfica," Dissertação, Centro de Ciências Humanas e Sociais Aplicadas, Pontifícia Universidade Católica de Campinas, Campinas - SP, 2010.

[11] R. L. L. Silva Filho, P. R. Motejunas, O. Hipólito, and M. B. d. C. M. Lobo, (2007, Set/Dez) A evasão no ensino superior brasileiro. *Cadernos de Pesquisa*. 641-659.

[12] V. Tinto, "Dropout from Higher Education: A Theoretical Synthesis of Recent Research," *Review of Educational Research*, vol. 45, pp. 89-125, Winter 1975.

[13] N. Viana and A. Rullán. (2010, Feb 20) Reflexiones sobre la deserción escolar en Finlandia y Puerto Rico. *Archivos Analíticos de Políticas Educativas*. 33.

[14] J. M. Gasper, S. DeLuca, and A. Estacion, "Switching Schools: Revisiting the Relationship Between School Mobility and High School Dropout," *American Educational Research Journal*, vol. 49, pp. 487-519, 1 Jun 2012.

[15] S. Pal, "Mining Educational Data Using Classification to Decrease Dropout Rate of Students," *International Journal of Multidisciplinary Sciences and Engineering*, vol. 3, pp. 35 - 39, MAY 2012.

[16] M. Jadrić, Ž. Garača, and M. Čukušić, "Student Dropout Analysis with Application of Data Mining Methods," *Journal of Contemporary Management Issues*, vol. 15, pp. 31-46, Jun 2010.

[17] S. L. Souza, "Evasão no ensino superior: um estudo utilizando a mineração de dados como ferramenta de gestão do conhecimento em um banco de dados referente à graduação de engenharia," Dissertação (Mestrado em Engenharia), Coordenação dos Programas de Pós-Graduação de Engenharia - COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 2008.

[18] A. Cripps, "Using artificial neural nets to predict academic performance," presented at the Proceedings of the 1996 ACM symposium on Applied Computing, Philadelphia, Pennsylvania, USA, 1996.

[19] S. T. Karamouzis and A. Vrettos, "An Artificial Neural Network for Predicting Student Graduation Outcomes," in: *World Congress on Engineering and Computer Science - WCECS - 2008*, San Francisco, USA, 2008, pp. 991-994.

[20] S. S. Haykin, *Redes Neurais: princípios e prática*, 2 ed. Porto Alegre - RS: Bookman Companhia Editora, 2001.

[21] S. Herzog, "Estimating student retention and degree-completion time: Decision trees and neural networks vis-à-vis regression," *New Directions for Institutional Research*, vol. 2006, pp. 17-33, Oct 2006.

[22] I. Lykourantzou, I. Giannoukos, V. Nikolopoulos, G. Mpardis, and V. Loumos, "Dropout prediction in e-learning courses through the combination of machine learning techniques," *Journal Computers & Education*, vol. 53, pp. 950-965, Nov 2009.

[23] M. N. Mustafa, L. Chowdhury, and S. Kamal, "Students dropout prediction for intelligent system from tertiary level in developing country," *International Conference on Informatics, Electronic s& Vision*. Dhaka, 2012.

[24] G. A. Carpenter, S. Grossberg, and J. H. Reynolds, "ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network," *Neural Netw.*, vol. 4, pp. 565-588, 1991.

[25] G. A. Carpenter, S. Grossberg, and D. B. Rosen, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system," *Neural Network*, vol. 4, pp. 759-771, 1991.

[26] S. C. Marchiori, M. C. G. da Silveira, A. D. P. Lotufo, C. R. Minussi, and M. L. M. Lopes, "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, 2011.

[27] L. A. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, pp. 338-353, 1965.

[28] J. A. Barnett, "Computational methods for a mathematical theory of evidence," presented at the Proceedings of the 7th international joint conference on Artificial intelligence, Vancouver, BC, Canada, 1981.