

SISTEMA INTELIGENTE PARA IDENTIFICAÇÃO DE GRUPOS DE RISCO RELACIONADOS À EVASÃO ESCOLAR

AN INTELLIGENT SYSTEM FOR IDENTIFYING RISKY GROUPS RELATED TO SCHOOL EVASION

Data de entrega dos originais à redação em: 04/03/2015
e recebido para diagramação em: 13/08/2015.

Leonardo Teodoro Araruna ¹

Thalita Alves dos Santos ²

Ana Helena Rufo Fiamengui ³

José Guilherme Magalini Santos Decanini ⁴

Neste artigo, apresenta-se um sistema inteligente para identificação de grupos de risco relacionados à evasão escolar. Atualmente, há uma preocupação latente dos órgãos reguladores da educação e das instituições de ensino no que tange à redução dos índices de evasão escolar. A partir disso, desenvolveu-se uma ferramenta de auxílio à tomada de decisão, a qual provê mais subsídios para os servidores envolvidos no processo de ensino e aprendizagem atuarem de modo assertivo e imediato evitando, assim, a possível evasão de discentes da instituição. Esse sistema foi concebido empregando uma rede neural artificial ARTMAP Fuzzy, que preserva duas características fundamentais: estabilidade e plasticidade. Esses dois atributos proporcionam aprendizagem estável e convergência rápida, requisitos essenciais para o desenvolvimento de um sistema robusto, confiável e com alta performance computacional. Os resultados obtidos foram promissores e evidenciaram a alta capacidade de generalização da rede, a rapidez e a confiabilidade dos prognósticos realizados.

Palavras-chave: Evasão Escolar. Sistema Inteligente. Ensino e Aprendizagem.

This paper presents an intelligent system for identifying risky groups related to school evasion. Nowadays, there is a latent concern of education regulators and educational institutions regarding the reduction of evasion rates. From this context, a support tool for decision-making was developed, which provides vital information to the servers involved in the teaching and learning process to act assertively and immediately, thereby preventing the possible students' evasion from the institution. This system was designed from an artificial neural network, ARTMAP Fuzzy, which preserves two fundamental characteristics: stability and plasticity. These attributes provide stable learning and rapid response, essential characteristics to enable the development of a robust and reliable system with high computing performance. The results were promising and evidenced the high generalization capability of the network, the computational performance and the reliability of the prognosis performed.

Keywords: School Evasion. Intelligent System. Teaching and Learning.

1 INTRODUÇÃO

Nos últimos anos, os Institutos Federais têm passado por um processo de expansão e reestruturação dos câmpus. Nesse sentido, houve um aumento relevante do número de vagas ofertadas e da criação de novos cursos, sejam eles técnicos, tecnológicos ou superiores. Concomitantemente a essa expansão, os Institutos Federais assinaram, juntamente com o Ministério da Educação (MEC), um termo de acordo de metas e compromissos, que tem como objetivo precípuo aumentar a eficácia das instituições a curto e médio prazo, demonstrando o reconhecimento pelo

governo federal da evasão como importante problema presente também nos sistemas federais de ensino e sua preocupação com o desenvolvimento de ações que garantam o bom uso dos recursos públicos.

O índice de eficácia relativo à evasão escolar é calculado, basicamente, pela relação entre o número de alunos concluintes e o número de alunos matriculados no período equivalente. Dessa forma, a evasão se configura como uma perda coletiva pois, como afirma Lobo (2012, p. 11), "o abandono do aluno sem a finalização dos seus estudos representa uma perda social, de recursos e de tempo de todos os envolvidos no

1 Discente do Curso de Tecnologia em Análise e Desenvolvimento de Sistemas - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Presidente Epitácio. Rua José Ramos Júnior, 27-50, 19470-000, Presidente Epitácio, SP, Brasil. <leonardo_araruna@hotmail.com >.

2 Técnica em Assuntos Educacionais - Graduação em Pedagogia - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Presidente Epitácio. Rua José Ramos Júnior, 27-50, 19470-000, Presidente Epitácio, SP, Brasil. (18) 3281-9583. <thalitaalves@ifsp.edu.br >.

3 Professora do Ensino Básico, Técnico e Tecnológico - Mestre em Estudos Linguísticos - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Presidente Epitácio. Rua José Ramos Júnior, 27-50, 19470-000, Presidente Epitácio, SP, Brasil. (18) 3281-9586. <anahelena@ifsp.edu.br >.

4 Professor do Ensino Básico, Técnico e Tecnológico - Doutor em Engenharia Elétrica - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Presidente Epitácio. Rua José Ramos Júnior, 27-50, 19470-000, Presidente Epitácio, SP, Brasil. (18) 3281-9586. <guilhermedecanini@ifsp.edu.br >.

processo de ensino, pois perdeu aluno, seus professores, a instituição de ensino, o sistema de educação e toda a sociedade". Dentro desse contexto, far-se-á necessário desenvolver ferramentas que auxiliem no processo de gestão da evasão e indiquem previamente grupos propícios a ela. Assim, esse prognóstico auxiliará o setor sociopedagógico, a coordenadoria de apoio ao ensino, os docentes e todos os servidores envolvidos no processo de ensino e aprendizagem em uma rápida e assertiva tomada de decisão que possibilite melhorar a aprendizagem e evitar a saída desses discentes da instituição.

As práticas tradicionais para identificação de grupos de risco relacionados à evasão escolar são fortemente dependentes do tempo e da capacidade perceptiva dos docentes. Nesta perspectiva, metodologias automáticas para identificação dos possíveis evadidos, que auxiliem os envolvidos no processo de ensino e aprendizagem, devem ser exploradas. Métodos baseados na inteligência artificial, *e.g.*, redes neurais artificiais, lógica *fuzzy* e sistemas especialistas representam técnicas disponíveis que objetivam extrair conhecimento de processos complexos (SILER; BUCKLEY, 2004; HAYKIN, 1994; ZADEH, 1965). Tais ferramentas procuram combinar a experiência dos envolvidos no processo com a execução de rotinas de forma segura, proporcionando maior robustez e confiabilidade nos prognósticos e podem proporcionar aperfeiçoamento na efetivação do processo de ensino e aprendizagem.

Com esse intuito, diversas pesquisas empregando técnicas de inteligência artificial têm sido realizadas para serem aplicadas no ambiente educacional. Destacam-se como trabalhos relevantes dessa natureza os que arrolamos a seguir. Musso et al. (2013) abordam a previsão do desempenho acadêmico por meio da análise de dados cognitivos, não-cognitivos e históricos empregando a rede neural artificial *perceptron* multicamadas. Hydaya et al. (2013) desenvolvem um modelo para classificação de estudantes utilizando lógica *fuzzy* e redes neurais. Martinho et al. (2013) apresentam um método para previsão da evasão discente em cursos superiores presenciais utilizando redes neurais artificiais da família ART. Jadric et al. (2010) analisam a evasão discente empregando técnicas de mineração de dados, *e.g.*, regressão logística e árvores de decisão. Oladokun et al. (2008) propõem um modelo utilizando a rede neural *perceptron* multicamadas para prever o desempenho de candidatos nos cursos de engenharia em universidades nigerianas. Cripps (1996) apresenta uma metodologia para que se identifique previamente o desempenho acadêmico dos discentes no que tange à formação, média de notas e horas creditadas empregando o algoritmo *backpropagation* com funções de ativação gaussiana, tangente hiperbólica e logística.

Neste artigo, apresenta-se a concepção de um sistema inteligente para identificação de grupos de risco quanto à evasão escolar. Uma ferramenta flexível e robusta é desenvolvida empregando a rede neural artificial ARTMAP *Fuzzy*, a qual é treinada de maneira supervisionada. Duas características possibilitam que ela seja utilizada em problemas de alta complexidade: estabilidade e plasticidade.

Estabilidade é a capacidade de aprender por meio do ajuste de pesos e plasticidade refere-se à capacidade de realizar o aprendizado continuado com a inclusão de novos padrões sem perder a memória previamente adquirida (CARPENTER et al., 1992). Por conseguinte, as respostas podem ser melhoradas ao longo do tempo, e o sistema adaptado às permanentes evoluções do setor educacional, o que consiste em significativa vantagem quando comparado às recentes metodologias.

O vetor de entrada da rede neural é composto por características dos discentes dos cursos técnicos do Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Presidente Epitácio. Mais especificamente, empregou-se o sistema para análise e prognóstico relativo à evasão escolar dos alunos dos cursos técnicos em Automação Industrial e em Edificações referente aos anos de 2011 a 2014. Dessa maneira, compôs-se dois bancos de dados, cada qual para um curso específico, tendo como base as informações provenientes dos registros acadêmicos dos discentes. Os resultados obtidos foram promissores e evidenciaram a alta capacidade de generalização e flexibilidade do sistema.

O artigo está organizado como descrito a seguir. A seleção das informações dos discentes é descrita na Seção 2. A Seção 3 destaca o pré-processamento e codificação das informações para composição do banco de dados. A Seção 4 apresenta o sistema de classificação. A composição da base de dados é detalhada na Seção 5. Os resultados e discussões são mostrados na Seção 6. Por último, na Seção 7, apresenta-se a conclusão do artigo.

2 SELEÇÃO DAS INFORMAÇÕES

O vetor de entrada da rede neural ARTMAP *Fuzzy* deve possuir informações relevantes que caracterizam os discentes (ZEFERINO, 2014). Essa composição corresponde ao ponto principal para o desenvolvimento de um eficaz sistema inteligente para identificação de grupos de risco relacionados à evasão escolar. A partir desse objetivo, selecionaram-se, por meio de uma busca exaustiva, as principais particularidades que possibilitam uma representação plena dos alunos evadidos e concluintes dos cursos técnicos em Automação Industrial e em Edificações. Informações sem relevância devem ser excluídas a fim de se obter um melhor desempenho computacional e evitar que o sistema realize a classificação de forma errônea. Dentro desta perspectiva, a melhor configuração obtida compreende as seguintes características: sexo, faixa etária, etnia, naturalidade, local de residência, advindo de escola pública ou particular, tempo ausente da escola, forma de ingresso e período do curso.

3 PRÉ-PROCESSAMENTO E CODIFICAÇÃO

Os valores que compõem os padrões de entrada da rede neural ARTMAP *Fuzzy* devem pertencer ao intervalo [0, 1] (CARPENTER et al., 1992). Portanto, as características selecionadas que representam a assinatura dos discentes devem ser pré-processadas e codificadas. A Tabela 1 mostra a codificação empregada para composição do vetor de entrada.

Tabela 1 - Codificação das características dos discentes

Características		Codificação	Nº de Bits
Sexo	Masc.	0	1
	Fem.	1	
Faixa etária	16 - 20	0 0 0 0	4
	21 - 25	0 0 0 1	
	26 - 30	0 0 1 0	
	31 - 35	0 0 1 1	
	36 - 40	0 1 0 0	
	41 - 45	0 1 0 1	
	46 - 50	0 1 1 0	
	51 - 55	0 1 1 1	
	56 - 60	1 0 0 0	
	61 - 65	1 0 0 1	
Maior que 65	1 0 1 0		
Etnia	Branco	0 0 0	3
	Amarelo	0 0 1	
	Indígena	0 1 0	
	Pardo	0 1 1	
	Negro	1 0 0	
Naturalidade	Fora	0	1
	Pres. Epitácio	1	
Residência	Fora	0	1
	Pres. Epitácio	1	
Escola	Particular	0	1
	Pública	1	
Anos sem estudar	0 - 2	0 0 0 0	4
	3 - 5	0 0 0 1	
	6 - 8	0 0 1 0	
	9 - 11	0 0 1 1	
	12 - 14	0 1 0 0	
	15 - 17	0 1 0 1	
	18 - 20	0 1 1 0	
	21 - 23	0 1 1 1	
	24 - 26	1 0 0 0	
	27 - 29	1 0 0 1	
Mais que 29	1 0 1 0		
Vestibular	Normal	0	1
	Simplificado	1	
Período	Vespertino	0	1
	Noturno	1	

basicamente por 2 módulos da teoria da ressonância adaptativa, ART Fuzzy A e ART Fuzzy B, conectados pelo módulo inter-ART. As designações ART Fuzzy e ARTMAP Fuzzy se devem à incorporação do operador AND fuzzy (\wedge) nos convencionais algoritmos ART e ARTMAP, respectivamente (DECANINI et al., 2011; GRANGER et al., 1997; GEORGIPOULOS et al., 1996; CARPENTER et al., 1992). Esta inclusão possibilita ao sistema trabalhar com números binários e analógicos pertencentes ao domínio [0, 1].

Um mecanismo interno denominado *match-tracking* é responsável pelo processo autorregulador da rede, no qual se maximiza a generalização e se minimiza o erro. Sempre que a rede realiza um prognóstico errado, através de uma conexão associativa instruída, o parâmetro de vigilância ρ_a do módulo ART Fuzzy A é incrementado em uma quantidade mínima necessária para corrigir o erro no módulo ART Fuzzy B.

O desempenho e aprendizado da rede neural ARTMAP Fuzzy depende essencialmente da especificação do parâmetro de vigilância (ρ), da taxa de treinamento (β) e do parâmetro de escolha (α).

O vetor de saída da rede neural é composto por apenas 1 bit, por meio do qual estabelece-se que: "0" corresponde à evasão e "1" refere-se aos concluintes, tendo em vista o uso da codificação binária.

4 REDE NEURAL ARTMAP FUZZY

A rede neural ARTMAP Fuzzy consiste em um sistema de aprendizado auto-organizável composto

O sistema inicializa sem nenhuma categoria ativa. Dessa maneira, os valores das matrizes de pesos, $\{W_{(Nx2Ma)}^a, W_{(Nx2Mb)}^b \text{ e } W_{(NxN)}^{ab}\}$, são iguais a 1 (CARPENTER et al., 1991). Os vetores de entrada e saída são representados por I^a e I^b , respectivamente, conforme descrito nas equações (1) e (2).

$$\mathbf{I}^a = \begin{bmatrix} \mathbf{a} & \mathbf{a}^c \end{bmatrix} = \begin{bmatrix} a_1 & a_2 & \dots & a_{Ma} & a_1^c & a_2^c & \dots & a_{Ma}^c \end{bmatrix} \quad (1)$$

$$\mathbf{I}^b = \begin{bmatrix} \mathbf{b} & \mathbf{b}^c \end{bmatrix} = \begin{bmatrix} b_1 & b_2 & \dots & b_{Mb} & b_1^c & b_2^c & \dots & b_{Mb}^c \end{bmatrix} \quad (2)$$

sendo:

$$a_i^c = 1 - a_i;$$

$$b_i^c = 1 - b_i;$$

Ma : dimensão de entrada;

Mb : dimensão de saída;

N : número de padrões de treinamento.

4.1 FASE DE TREINAMENTO

O treinamento da rede neural ARTMAP Fuzzy pode ser realizado de maneira lenta ($0 < \beta < 1$) ou rápida ($\beta = 1$). A seguir, apresenta-se o algoritmo para treinamento da rede neural.

1º Passo: Ler todos os parâmetros da rede ($\alpha, \beta, \rho_a, \rho_b, \rho_{ab}$ e ε);

2º Passo: Inicializar as matrizes de pesos (todos os pesos das matrizes $\mathbf{W}_{(Nx2Ma)}^a, \mathbf{W}_{(Nx2Mb)}^b$ e $\mathbf{W}_{(NxN)}^{ab}$ possuem valor inicial igual a 1);

3º Passo: Compor o vetor de entrada: $\mathbf{I}^a = \begin{bmatrix} \mathbf{a} & \mathbf{a}^c \end{bmatrix}$, e o vetor de saída: $\mathbf{I}^b = \begin{bmatrix} \mathbf{b} & \mathbf{b}^c \end{bmatrix}$;

4º Passo: Verifique se a lista de padrões de treinamento foi concluída:

Se Sim, o processo de treinamento é concluído;

Se Não, vá para o 5º Passo;

5º Passo: Atribuir $\rho_a = \rho_a$;

6º Passo: Calcule a função de escolha, T_k^b :

$$T_k^b = \frac{|\mathbf{I}^b \wedge \mathbf{W}_k^b|}{\alpha + |\mathbf{W}_k^b|}, \text{ para } k = 1, 2, \dots, N;$$

7º Passo: Escolha a categoria do módulo ART FuzzyB: $kv = \arg \left\{ \max T_k^b \right\}$, para $k = 1, 2, \dots, N$;

8º Passo: Verifique o critério de vigilância do

$$\text{módulo ART Fuzzy B: } \frac{|\mathbf{I}^b \wedge \mathbf{W}_{kv}^b|}{|\mathbf{I}^b|} \geq \rho_b:$$

Se Sim, vá para o 9º Passo;

Se Não, realize o reset: atribua $T_{kv}^b = 0$ e retorne ao 7º Passo;

9º Passo:

Compute $\mathbf{Y}^b = \left[Y_1^b \ Y_2^b \ \dots \ Y_N^b \right]$:

$$Y_{kv}^b = 1;$$

$$Y_k^b = 0, \text{ para } k = 1, 2, \dots, N \text{ e } k \neq kv;$$

10º Passo:

Adaptação dos pesos do módulo ART Fuzzy B:

$$\mathbf{W}_{kv}^b (\text{novo}) = \beta \left(\mathbf{I}^b \wedge \mathbf{W}_{kv}^b (\text{velho}) \right) + (1 - \beta) \mathbf{W}_{kv}^b (\text{velho})$$

11º Passo:

Calcule a função de escolha, $T_j^a: T_j^a = \frac{|\mathbf{I}^a \wedge \mathbf{W}_j^a|}{\alpha + |\mathbf{W}_j^a|}$, para $j = 1, 2, \dots, N$;

12º Passo: Escolha a categoria do módulo ART

FuzzyA: $jv = \arg \left\{ \max T_j^a \right\}$, para $j = 1, 2, \dots, N$;

13º Passo: Verifique o critério de vigilância do

$$\text{módulo ART Fuzzy A: } \frac{|\mathbf{I}^a \wedge \mathbf{W}_{jv}^a|}{|\mathbf{I}^a|} \geq \rho_a:$$

Se Sim, vá para o 14º Passo;

Se Não, realize o reset: atribua $T_{jv}^a = 0$ e retorne ao 12º Passo;

14º Passo: Verifique o critério de vigilância do

$$\text{módulo inter-ART: } \frac{|\mathbf{Y}^b \wedge \mathbf{W}_{jv}^{ab}|}{|\mathbf{Y}^b|} \geq \rho_{ab}:$$

Se Sim, vá para o 15º Passo;

Se Não, incremente o parâmetro de vigilância

$$\rho_a, \rho_a = \frac{|\mathbf{I}^a \wedge \mathbf{W}_{jv}^a|}{|\mathbf{I}^a|} + \varepsilon, \text{ atribua } T_{jv}^a = 0 \text{ e}$$

retorne ao 12º Passo;

15º Passo: Adaptação dos pesos do módulo ART Fuzzy A:

$$W_{jv}^a (novo) = \beta \left(I^a \wedge W_{jv}^a (velho) \right) + (1 - \beta) W_{jv}^a (velho);$$

16º Passo: Adaptação dos pesos do módulo inter-ART: $W_{jv}^{ab} = [W_{jv,1}^{ab} \ W_{jv,2}^{ab} \ \dots \ W_{jv,N}^{ab}]$:

$$W_{jv,kv}^{ab} = 1;$$

$$W_{jv,k}^{ab} = 0, \text{ para } k = 1, 2, \dots, N \text{ e } k \neq kv;$$

17º Passo: Retorne ao 4º Passo. sendo:

$$r \wedge s = \min(r_i, s_i);$$

$$\arg \{ \max T_j \} : \text{índice do } T_j \text{ máximo};$$

jv : neurônio vencedor do módulo ART Fuzzy A;
 kv : neurônio vencedor do módulo ART Fuzzy B;
 ρ_a : parâmetro de vigilância inicial;

ε : incremento do parâmetro de vigilância ρ_a .

4.2 Fase de teste

A etapa de teste da rede neural ARTMAP Fuzzy dar-se-á da seguinte maneira:

1º Passo: Compõe-se o vetor de teste I^a baseado nas características codificadas;

2º Passo: Determine o neurônio vencedor do módulo ART Fuzzy A (jv);

3º Passo: Calcule I^b :

$$I^b = W_{jv}^{ab} W^b = [\underline{b}_1 \ \underline{b}_2 \ \dots \ \underline{b}_{Mb} \ \underline{b}_1^c \ \underline{b}_2^c \ \dots \ \underline{b}_{Mb}^c];$$

4º Passo: Identifica-se a codificação de saída representativa do grupo de risco relacionado à evasão e dos alunos concluintes \underline{b} :

$$\underline{b} = [\underline{b}_1 \ \underline{b}_2 \ \dots \ \underline{b}_{Mb}].$$

5 BASE DE DADOS

A base de dados para o sistema inteligente para identificação de grupos de risco relacionados à evasão escolar foi construída utilizando as informações provenientes dos registros acadêmicos dos discentes do curso Técnico em Automação Industrial e do curso Técnico em Edificações do Câmpus Presidente Epitácio referentes aos anos de 2011 a 2014.

5.1 Conjuntos de treinamento e de teste

O banco de dados contém informações relativas a 438 discentes, *i.e.*, é composto por 438 padrões,

sendo que 153 padrões correspondem ao conjunto de treinamento e 66 padrões consistem no conjunto de teste relativos ao curso Técnico em Automação Industrial. Também no âmbito do curso Técnico em Edificações, tem-se 153 padrões de treinamento e 66 de teste.

5.2 Sistema computacional

A implementação computacional da base de dados emprega o sistema de gerenciamento de banco de dados de código-fonte aberto MySQL devido a sua flexibilidade, confiabilidade e velocidade.

O sistema inteligente foi desenvolvido utilizando a linguagem de programação C.

6 RESULTADOS

A metodologia proposta para identificação de grupos de risco relacionados à evasão escolar usando inteligência artificial apresentou robustez no que diz respeito às dificuldades comumente encontradas no processo de determinação prévia de discentes com maior risco de evasão.

O desenvolvimento de um sistema eficiente para a identificação de grupos de risco deve contemplar duas etapas fundamentais: extração das principais características dos alunos (*assinatura*) e análise de dados utilizando modernas técnicas de processamento de informações. Na primeira etapa, selecionaram-se as principais particularidades que possibilitam uma representação plena dos alunos evadidos e concluintes, *i.e.*, sexo, faixa etária, etnia, naturalidade, local de residência, advindo de escola pública ou particular, tempo ausente da escola, forma de ingresso e período do curso. Na segunda etapa empregou-se a rede neural artificial ARTMAP Fuzzy, a qual provê capacidade de generalização, confiabilidade e alto desempenho computacional. A correta especificação de seus parâmetros contribui para uma melhora na performance do sistema de identificação. Dentro desse contexto, os valores utilizados dos parâmetros da rede neural foram: $\alpha = 0,1$, $\beta = 1$, $\rho_a = 0,2$, $\rho_b = 1$, $\rho_{ab} = 0,95$ e $\varepsilon = 0,01$.

O sistema inteligente para identificação de grupos de risco relacionados à evasão escolar obteve 92,4% de acerto nos diagnósticos referentes aos discentes do curso Técnico em Automação Industrial e 90,9% de acerto nos diagnósticos relativos aos discentes do curso Técnico em Edificações. O sistema de classificação ora apresentado necessitou de apenas uma época para apresentar o resultado supracitado. Por conseguinte, essa arquitetura apresenta melhor desempenho computacional quando comparado às tradicionais técnicas, *e.g.*, o algoritmo *backpropagation* requer um número maior de épocas para obter resultados similares.

A ferramenta desenvolvida proporciona aos envolvidos no processo de ensino e aprendizagem maior suporte para o planejamento de ações que visem à efetivação de uma educação democrática e de qualidade (proatividade).

7 CONCLUSÕES

Neste artigo foi apresentado um moderno sistema inteligente para identificação de grupos de risco relacionados à evasão escolar. Esse tipo de prognóstico auxilia o setor sociopedagógico, a coordenação de apoio ao ensino, os docentes e todos os servidores envolvidos no processo de ensino e aprendizagem em uma rápida e assertiva tomada de decisão, que possibilita melhorar a aprendizagem e evitar a saída desses discentes da instituição, corroborando assim, para que a democratização da educação seja efetivada.

O sistema inteligente foi desenvolvido tendo como base as informações disponíveis nos registros escolares do Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Presidente Epitácio relativas aos cursos Técnico em Automação Industrial e Técnico em Edificações. Ressalta-se que as principais publicações no que tange à evasão escolar estão direcionadas aos cursos superiores. Nesse sentido, propôs neste trabalho um método para prognóstico de grupos de risco relacionados à evasão escolar no âmbito de cursos técnicos, cursos estes em franca expansão e fundamentais para o desenvolvimento sustentável do país, motivo pelo qual deve haver um interesse contínuo e crescente relacionado à efetivação do processo de ensino e aprendizagem também em cursos FIC, Pronatec, cursos de curta duração, entre outros.

A utilização de técnicas de inteligência artificial propicia maior flexibilidade, segurança e eficiência, características imprescindíveis para o processo de tomada de decisão. A possibilidade de inclusão do treinamento continuado representa outra vantagem sobre as técnicas tradicionais apresentadas na literatura especializada. Nas redes neurais, a inserção de um novo padrão para treinamento requer a reinicialização deste processo, enquanto que na rede ARTMAP *Fuzzy*, esse reforço pode ser realizado continuamente sem perda do conhecimento previamente adquirido. Tal concepção possibilita o aperfeiçoamento dos resultados ao longo do tempo. Por fim, estudos que abordam a análise e prognóstico da evasão escolar em cursos técnicos e em cursos de curta duração possuem relevância fundamental para o aperfeiçoamento das instituições e para a democratização da educação.

AGRADECIMENTOS

Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo e ao projeto de pesquisa oriundo do "Pró-Equipamentos IFSP" pelo suporte financeiro e de infraestrutura concedidos.

REFERÊNCIAS

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance theory. **Neural Network**, Oxford, v. 4, n. 1, p. 759-771, 1991.

CARPENTER G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture

for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Network**, Piscataway, v. 3, n. 5, p. 698-713, 1992.

CRIPPS, AI. Using artificial neural nets to predict academic performance. In: Symposium on Applied Computing, 1996, Philadelphia. **Proceedings...** Philadelphia, Pennsylvania, USA: ACM: p. 33-37, 1996.

DECANINI, J. G. M. S.; TONELLI-NETO, M. S.; MALANGE, F. C. V.; MINUSSI, C. R. Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network, **Electric Power Systems Research**, Lausanne, v. 81, n. 12, p. 2057-2065, 2011.

GEORGIPOULOS, M.; FERNLUND, H.; BEBIS, G.; HEILMAN, G. L. Order of search in fuzzy ART and fuzzy ARTMAP: effect of the choice parameter. **Neural Network**, Oxford, v. 9, n. 9, p. 1541-1559, 1996.

GRANGER, E.; BLAQUIÈRE, Y.; SAVARIA, Y.; CANTIN, M.-A.; LAVOIE, P. A VLSI architecture for fast clustering with fuzzy ART neural networks. **International Journal of Microelectronics System Integration**, New York, v. 5, n. 1, p. 3-18, 1997.

HAYKIN, S. **Neural Networks: A comprehensive foundation**. Upper Saddle River: Prentice-Hall, 1994.

HYDAYA, I.; PERMANASARI, A. E.; RATWASTUTI, N. Student classification for academic performance prediction using neuro fuzzy in a conventional classroom. In: International Conference on Information Technology and Electrical Engineering, 2013, Yogyakarta. **Proceedings...** Piscataway: IEEE, p. 221-225, 2013.

JADRIC, M.; GARAČA, Ž.; ČUKUŠIĆ, M. Student dropout analysis with application of data mining methods. **Journal of Contemporary Management**, Toronto, v. 15, n. 1, p. 31-46, 2010.

LOBO, M. B. C. M. Panorama da evasão no ensino superior brasileiro: aspectos gerais das causas e soluções. In: Evasão no ensino superior brasileiro. **Caderno ABMES**: 25, p. 9-58, 2012.

MARTINHO, V. R. C.; NUNES, C.; MINUSSI, C. R. Predição do grupo de risco de evasão discente em cursos superiores presenciais utilizando uma rede neural ARTMAP-Fuzzy. In: XLI Congresso Brasileiro de Educação em Engenharia, Gramado. **Anais...** Gramado: COBENGE, p. 1-6, 2013.

MUSSO, M. F.; KYNDT, E.; CASCALLAR, E. C.; DOCHY, F. Predicting general academic performance and identifying the differential contribution of participating variables using artificial neural networks. **Frontline Learning Research**, Leuven, v. 1, p. 42-71, 2013.

OLADOKUN, V. O.; ADEBANJO, A. T.; CHARLES-OWABA, O. E. Predicting students' academic performance using artificial neural network: a case study of an engineering course. **The Pacific Journal of Science and Technology**, Hilo, v. 9, n. 1, p. 72-79, 2008.

SILER, W.; BUCKLEY, J. J. **Fuzzy Expert Systems and Fuzzy Reasoning**. Hoboken: John Wiley & Sons, 2004.

ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, n. 3, p. 338-353, 1965.

ZEFERINO, P. G. F. Mineração de dados aplicada para levantamento do perfil dos alunos dos cursos técnicos oferecidos pelo câmpus Campos do Jordão do IFSP. **Sinergia**, São Paulo, v. 15, n. 1, p. 14-25, 2014.